

**UNIVERSIDAD COMPLUTENSE DE MADRID**

FACULTAD DE INFORMÁTICA

DEPARTAMENTO DE ARQUITECTURA DE COMPUTADORES Y  
AUTOMÁTICA



**TESIS DOCTORAL**

**Aplicaciones de los algoritmos evolutivos al análisis de procesos económicos**

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

**Francisco José Soltero Domingo**

Directores

José Ignacio Hidalgo Pérez  
Pablo Fernández Blanco

**Madrid, 2014**



**UNIVERSIDAD COMPLUTENSE DE MADRID**

**Departamento de Arquitectura de Computadores y Automática**

**Madrid, España.**

**APLICACIONES DE LOS ALGORITMOS  
EVOLUTIVOS AL ANÁLISIS DE PROCESOS  
ECONÓMICOS**

**Memoria para optar al grado de doctor**

**Presentada por**

**D. Francisco José Soltero Domingo**

**Directores:**

**Dr. D. José Ignacio Hidalgo Pérez**

**Dr. D. Pablo Fernández Blanco.**



**“Carpe diem quam minimum credula postero”**

**Horacio (Odas, I, 11)**



## Agradecimientos

Deseo hacer llegar mi agradecimiento a todas las Instituciones y personas que me han ayudado y animado estos años y sin las que no habría podido llegar hasta aquí.

En primer lugar a mis Directores de tesis, José Ignacio Hidalgo y Pablo Fernández, que me descubrieron este campo de conocimiento y me dieron la posibilidad de poder hacer este trabajo. Sin su aliento y apoyo constante no lo hubiera conseguido, gracias de todo corazón.

A la Facultad de Informática, y especialmente al departamento de Arquitectura de Computadores y Automática, por brindarme todos los medios para poder realizar esta tesis. Al Centro de Estudios Superiores Felipe II por permitirme utilizar sus instalaciones e infraestructura y por el apoyo de su personal técnico.

A mi compañero Diego J. Bodas por su ayuda desinteresada y enseñanzas, y a todos los profesores del CES Felipe II que han compartido días de trabajo conmigo.

A toda mi familia, especialmente a mis padres por todos los sacrificios que han realizado para que yo pudiera estudiar. A todos mis amigos del Instituto de Salud Carlos III y de CEPAL, que me han ayudado y animado constantemente. A Eduardo Yagüe, por su cariño y consejos.

A mis dos hijas Lola y Marta y a mi mujer Laura por sopórtame a pesar de todos mis defectos.

A todos muchas gracias.



## RESUMEN

Esta tesis doctoral se centra en el desarrollo de una técnica multiobjetivo para la toma de decisiones en los mercados financieros internacionales. El proceso económico es el conjunto de actividades económicas que realizan los hombres con el fin de obtener los medios que le permitan satisfacer sus necesidades. En este trabajo los procesos económicos analizados se refieren a la operativa en los mercados financieros internacionales y más concretamente a los relacionados con el mercado de divisas. El mecanismo que utilizan los agentes para evaluar sus expectativas y tomar sus decisiones es extremadamente complejo debido a la gran cantidad de variables posibles, y a la limitación temporal para definir las. Por otra parte, los algoritmos evolutivos son métodos de optimización y búsqueda de soluciones utilizados principalmente en problemas con espacios de búsqueda extensos y no lineales, en donde otros métodos no son capaces de encontrar soluciones en un tiempo razonable. Por tanto, el objetivo es encontrar una técnica que permita generar soluciones en estos mercados a partir del uso de estos algoritmos. Para ello, se realiza un estudio de la aportación que éstos realizan en la mejora de toma de decisiones, validándose la propuesta con experimentos en los cuales se consiguen grandes mejoras en los beneficios, comparados con otras técnicas tradicionales como "buy and hold". Complementariamente, y acorde a los estudios realizados se presenta el diseño de una herramienta para la toma de decisiones en tiempo real en el mercado de divisas.





## **ABSTRACT**

This thesis focuses on the development of a technique for multi-objective decision-making in international financial markets. The economic process is the set of economic activities that men do to get the resources to enable it to meet your needs. This is done in society and is a continuous and interrelated process that is grouped into five phases: production, circulation, distribution, consumption and investment. Thus, an economical process may be simply the sale of a product or service. Economic processes analyzed in this work relate to the operations performed in the international financial markets and more specifically related to the currency market. The process used by the agents to evaluate your expectations and make decisions is extremely complex due to the large number of possible variables and temporary restrictions. Moreover, evolutionary algorithms are methods of optimization problems are mainly used in large search spaces and nonlinear, where other methods are not able to find solutions in a reasonable time. Therefore, the goal is to find a technique to provide solutions in these markets from the use of these algorithms. In this work we have studied the contribution that evolutionary algorithms perform in improving decision making in these markets. This proposal has been validated through experiments, which achieved great improvements in profits, compared with other traditional techniques such as buy and hold. In addition, and according to studies, the design of a computer application to decision making in real time on the forex market is presented.



# ÍNDICE

Introducción .....	27
Objetivos de la tesis .....	30
Estructura de la tesis .....	33
1. Conceptos Económicos .....	35
1.1.- Economía y mercados de divisas .....	37
1.1.1.- El Mercado de Divisas .....	42
1.1.2.- El tipo de cambio.....	43
1.1.3.- Variaciones en el tipo de cambio. ....	45
1.1.4.- Los mercados de capitales y deuda internacionales.....	48
1.1.5.- Política Monetaria.....	48
1.1.5.1.- Tipos de política monetaria .....	49
1.2.- Predicción en mercados financieros .....	50
1.2.1.- Análisis cuantitativo .....	50
1.2.2.- Análisis técnico.....	51
1.2.2.1- La hipótesis de los mercados eficientes.....	52
1.2.2.2- Visión histórica del análisis técnico.....	55
1.2.3.- Computación evolutiva en economía .....	56
1.3.- Introducción a los indicadores técnicos.....	57
1.3.1.- Indicadores de tendencia.....	58
1.3.1.1.- MACD .....	58
1.3.2.- Indicadores de momento.....	59
1.3.2.1.- Estocástico .....	59
1.4.- Definiciones.....	60
1.5.- Conclusiones y resumen .....	62
2. Algoritmos Evolutivos.....	63
2.1 Optimización y Heurística .....	65
2.1.1.- Optimización global y multiobjetivo .....	65
2.1.2.- Complejidad computacional y heurística.....	70
2.1.2.1.- Complejidad computacional .....	70
2.1.2.2.- Heurística .....	71
2.1.2.3.- Ventajas de los algoritmos heurísticos .....	72

2.1.2.4.- Desventajas de los algoritmos heurísticos.....	72
2.1.3.- Algoritmos de optimización .....	73
2.1.4.- Métodos heurísticos de optimización.....	73
2.2. – Introducción a los algoritmos evolutivos .....	74
2.2.1.- Breve historia de los EAs.....	74
2.2.2.- Fundamentos de los EAs .....	76
2.2.2.1.- Programación evolutiva .....	78
2.2.2.2.- Estrategias evolutivas .....	79
2.2.2.3.- Programación Genética.....	79
2.2.2.4.- Algoritmos Genéticos.....	79
2.3. – Terminología de los algoritmos genéticos. ....	80
2.4.- Tipos de codificación.....	81
2.5.- Operadores genéticos. ....	81
2.5.1.- Operador de inicialización.....	82
2.5.2.- Operadores de reproducción.....	82
2.5.2.1.- Operador de cruce .....	82
2.5.2.1.1. Cruce binario simulado (SBX- $\beta$ ).....	83
2.5.2.2.- Operador de mutación.....	85
2.5.2.2.1.- Operador de mutación polinomial.....	86
2.5.2.3.- Operador de selección .....	87
2.5.2.3.1.- Selección por torneo.....	87
2.5.2.4.- Operador de remplazo.....	89
2.6.- Ajuste de los parámetros y criterios de detención. ....	89
2.7.- La función de aptitud o función objetivo.....	90
2.7.1.- Convergencia del los EAs. ....	91
2.8.- Algoritmos evolutivos para la optimización multiobjetivo .....	91
2.8.1.- Procesos de evaluación y selección .....	92
2.8.2.- Diversidad de la población.....	93
2.8.3.- Elitismo.....	94
2.8.4.- Clasificación de los algoritmos multiobjetivo .....	95
2.8.4.1.- Algoritmos multiobjetivo con elitismo.....	96
2.8.4.1.1. - Strength Pareto Evolutionary Algorithm (SPEA). ....	97
2.8.4.1.2. - Strength Pareto Evolutionary Algorithm (SPEA-2). ....	97
2.8.4.1.3. - Pareto Archived Evolution Strategy (PAES).....	98

2.8.4.1.4. - Non-dominated Sorting Genetic Algorithm-II (NSGA II).	99
2.8.4.1.5.- Niched-Pareto Genetic Algorithm (PESA y PESA-2).	100
2.8.4.1.6.- Multi-Objective Messy Genetic Algorithm (MOMGA y MOMGA-2).	100
2.8.4.1.7. - Niched-Pareto Genetic Algorithm (NPGA II).	101
2.8.4.1.8. - Micro Genetic Algorithm for Multiobjective Optimization (Micro GA).	101
2.8.4.1.9. – Algoritmo multi-objetivo MoCell.	101
2.9 Conclusiones.	103
3. Aplicación de los algoritmos evolutivos para la gestión de estrategias de “trading”	105
3.1.- Introducción.	107
3.1.1.- Descripción de la arquitectura	108
3.2. Selección de parámetros, complejidad intrínseca	110
3.2.1 Generación de señales de entrada y salida al mercado de los indicadores.	110
3.2.2. Generación interna de señales por parte de los indicadores.	112
3.2.3.- Selección de los cromosomas que compondrán el gen para cada individuo.	115
3.2.3.1.- Cromosomas relacionados con los indicadores.	115
3.2.3.2.- Cromosomas relacionados con las ventanas temporales.	115
3.2.3.3.- Cromosomas relacionados con la operativa del mercado.	118
3.2.3.4.- Cromosomas relacionados con la generación de señales.	118
3.2.3.4.1 MACD	118
3.2.3.4.2 Estocástico.	119
3.2.4. Definición del gen.	119
3.3.- Selección de los objetivos.	120
3.3.1.- Conceptos relacionados	120
3.3.1.1.- HPR. (“Holding Period Return”)	120
3.3.1.2.- TWR (“Terminal Wealth Relative”) o Riqueza relativa.	120
3.3.1.3.- Expectativa matemática.	120
3.3.1.4.- La ecuación fundamental de “trading”	121
3.3.2.- Funciones objetivo	121
3.3.2.1.- Función objetivo 1: maximizar la media aritmética (maximizar el retorno).	122
3.3.3.2.- Función objetivo 2: Minimizar el riesgo de la estrategia.	124
3.3.3.4.- Funciones objetivo 3: Maximizar el número de operaciones	126
3.4.- Análisis del conjunto de datos de la experimentación.	127
3.5.- Sistemas de negociación de alta frecuencia	129
3.6.- Conclusiones.	132

4. Implementación del algoritmo genético para la gestión de estrategias de “trading” .....	133
4.1 Introducción .....	135
4.2 La librería JMetal .....	135
4.3 Selección del algoritmo multiobjetivo .....	136
4.3.1.- Evaluación de los resultados .....	136
4.3.2.- Aproximación del frente de Pareto óptimo .....	138
4.3.3.- Selección del algoritmo evolutivo para el problema propuesto .....	139
4.3.3.1.- Resultados Conjunto 1 .....	141
4.3.3.2.- Resultados Conjunto 2 .....	143
4.3.3.3.- Resultados Conjunto 3 .....	145
4.3.4.- Resumen del análisis de los algoritmos evolutivos seleccionados. ....	147
4.4 Análisis de los parámetros del algoritmo SPEA-II .....	147
4.4.1.- El operador de inicialización .....	147
4.4.2.- La función de aptitud .....	148
4.4.3.- Análisis de los operadores de selección y ajuste de parámetros .....	148
4.4.4.- Análisis de los operadores de cruce y ajuste de parámetros .....	149
4.4.5.- Análisis de los operadores de mutación y ajuste de los parámetros .....	150
4.4.6.- El tamaño de la población .....	151
4.4.7.- Ajuste del número de evaluaciones .....	153
4.4.8.- Configuración óptima seleccionada .....	154
4.5 Conclusiones de Capítulo .....	154
5. Resultados .....	155
5.1.- Introducción .....	157
5.2. Análisis de los valores obtenidos por los parámetros .....	157
5.2.1.- Cromosomas relacionados con los indicadores .....	158
5.2.1.1.- MACD .....	158
5.2.1.3.- Estocástico. ....	163
5.2.3.- Cromosomas relacionados con la operativa del mercado .....	167
5.2.4.- Cromosomas relacionados con las ventanas temporales .....	169
5.3.- Dinámica del sistema. ....	170
5.4.- Comparativa de resultados con parámetros estándar. ....	176
5.4.1.- Resultados conjunto 1 .....	177
5.4.1.- Resultados conjunto 2 .....	185
5.4.3.- Resultados conjunto 3 .....	193

5.5.- Comparativa frente a resultados obtenidos por otras estrategias.....	201
5.6.- Conclusiones al capítulo.....	203
6. Conclusiones.....	205
7. Publicaciones.....	209
8. Bibliografía .....	211
9. Summary in English .....	247
9.1. - Introduction .....	248
9.2. - Main objectives of this thesis.....	250
9.3. - Thesis structure.....	252
9.4. - Application of evolutionary algorithms for managing trading strategy.....	254
9.4.1 Introduction.....	254
9.4.2. - Architectural Overview .....	255
9.4.3. - Definition of the proposed gene. ....	258
9.4.4. - Results obtained in the algorithm selection .....	259
9.4.5. - Optimal configuration for the algorithm selected .....	259
9.5. - Results .....	260
9.6. - Conclusions .....	263



## ÍNDICE DE FIGURAS

Figura 1.- Índice Bigmac ( <a href="http://www.economist.com/content/big-mac-index">http://www.economist.com/content/big-mac-index</a> ).....	46
Figura 2.- Política monetaria restrictiva (Izquierda) y expansiva (derecha) <a href="http://es.wikipedia.org/wiki/Pol%C3%ADtica_monetaria">http://es.wikipedia.org/wiki/Pol%C3%ADtica_monetaria</a> .....	50
Fig. 3: Ejemplo de optimalidad en el espacio objetivo (izquierda) y una posible relación de las soluciones en el espacio objetivo (derecha). .....	67
Fig. 4: Conjunto de soluciones localmente óptimas y conjunto de soluciones globalmente óptimas en el espacio objetivo. ....	69
Figura 5.- Algoritmo evolutivo típico.....	78
Figura 6.- Region factible $Q=[0,1]^2$ . Algoritmo 3.1 genera 100 mutaciones de una descendencia. En algunos casos el individuo mutado queda fuera de la zona factible (izquierda). El fdp utiliza la mutación polinomial para valores de $\eta=2$ y 6. ....	86
Figura 7.- Frente de Pareto multiobjetivo.....	108
Figura 8.- Arquitectura del Sistema.....	109
Figura 9.- Tendencia alcista y bajista. ....	111
Figura 10.- Detalle cambio de tendencia indicador MACD ( Figura generada con Metatrader 4.0). ....	113
Figura 11. Significado gráfico de los parámetros MACDpa y MACDpb ( Figura generada con Metatrader 4.0).....	114
Figura 12.- Indicador Estocástico ( Figura generada con Metatrader 4.0).....	114
Figura 13.- Factor de beneficio para la estrategia clásica del macd. ....	116
Figura 14.- Numero de operaciones.....	116
Figura 15.- Número de operaciones para la estrategia por años. ....	117
Figura 16.- Conjunto de datos par EUR/USD desde 30/09/1999 al 30/09/2009 .....	127
Figura 17.- 1 de abril de 2004 a 30 de junio de 2004.....	128
Figura 18.- 27 de marzo de 2006 al 30 de junio de 2006.....	128
Figura 19.- 31 de marzo de 2008 al 30 de junio de 2008.....	129
Figura 20.- Cantidad de soluciones no dominadas encontradas. ....	141
Figura 21.- Soluciones encontradas y con actividad para el conjunto de datos 1 .....	142
Figura 22.- Número de operaciones totales y duración media de las soluciones para el conjunto de datos 1.....	142
Figura 23.- Beneficio Total y beneficio promedio por operación para el conjunto de datos 1. ....	143
Figura 24.- Soluciones encontradas y con actividad para el conjunto de datos 2 .....	144
Figura 25.- Número de operaciones y duración media de las soluciones para el conjunto de datos 2.....	144
Figura 26.- Beneficio Total y beneficio promedio por operación para el conjunto 2 .....	145
Figura 27.- Soluciones encontradas y con actividad del conjunto de datos 3 .....	146
Figura 28.- Número de operaciones y duración media de las soluciones para el conjunto de datos 3.....	146
Figura 29.- Beneficio Total y beneficio promedio por operación para el conjunto de datos 3 .....	147
Figura 30.- Soluciones encontradas no dominadas y con actividad para ambos operadores de selección.....	148
Figura 31.- Número de operaciones totales y beneficio promedio para ambos operadores de selección.....	148

Figura 32.- Beneficio total para ambos operadores de selección.....	149
Figura 33.- Soluciones encontradas no dominadas y con actividad para ambos operadores de cruce.....	149
Figura 34.- Número de operaciones totales y beneficio promedio para ambos operadores de cruce.....	150
Figura 35.- Beneficio total para ambos operadores de cruce.....	150
Figura 36.- Soluciones encontradas no dominadas y con actividad para las distintas probabilidades de mutación. ....	150
Figura 37.- Número de operaciones totales y beneficio promedio para las distintas probabilidades de mutación. ....	151
Figura 38.- Beneficio total para las distintas probabilidades de mutación.....	151
Figura 39.- Soluciones encontradas no dominadas y con actividad para las poblaciones.....	151
Figura 40.- Número de operaciones totales y beneficio promedio para las poblaciones. ....	152
Figura 41.- Beneficio total para las poblaciones. ....	152
Figura 42.- Número de soluciones encontradas y de operaciones totales para una población de 10 individuos con un fichero externo de 10 soluciones.....	153
Figura 43.- Beneficio total para una población de 10 individuos con un fichero externo de 10 soluciones.....	153
Figura 44.- Beneficio total para distintas evaluaciones del algoritmo genético. ....	153
Figura 45.- Soluciones encontradas en orden de aparición para el parámetro 1.....	158
Figura 46.- Soluciones encontradas en orden de aparición parámetro 2.....	158
Figura 47.- Soluciones encontradas en orden de aparición parámetro 3.....	159
Figura 48.- distribución de valores para el parámetro 1 del MACD.....	159
Figura 49.- Cantidad de valores encontrados parámetro 2 del MACD .....	160
Figura 50.- Cantidad de valores encontrados parámetro 3 del MACD .....	160
Figura 51.- MACD para las soluciones no dominadas del último intervalo. Parámetro 1: azul; Parámetro 2: rojo; Parámetro 3: verde.....	161
Figura 52.- Representación del las distancias en el Histograma del MACD.....	161
Figura 53.- Distancia de compra para el MACD (parámetro $MACD_{pa}$ ) .....	162
Figura 54.- Distancia de venta para el MACD (parámetro $MACD_{pb}$ ) .....	162
Figura 55.- Soluciones encontradas en orden de aparición para el parámetro 1 del estocástico .....	163
Figura 56.- Soluciones encontradas en orden de aparición para el parámetro 2 del estocástico .....	163
Figura 57.- Soluciones encontradas en orden de aparición para el parámetro 3 del estocástico .....	164
Figura 58.- Distribución de valores para el parámetro 1 del estocástico .....	164
Figura 59.- Distribución de valores para el parámetro 2 del estocástico .....	165
Figura 60.- Distribución de valores para el parámetro 3 del estocástico .....	165
Figura 61.- Estocástico para las soluciones no dominadas del último intervalo. Parámetro 1: azul; parámetro 2: rojo; parámetro 3: verde .....	166
Figura 62.- Resultados obtenidos para el parámetro $EST_{pa}$ .....	166
Figura 63.- Resultados obtenidos para el parámetro $EST_{pb}$ .....	167
Figura 64.- Resultados para el parámetro “stop-loss” .....	168
Figura 65.- Resultados para el parámetro del “take-profit” .....	168

Figura 66.- Resultados para el parámetro “Trailing-Stop” .....	169
Figura 67.- Resultados del parámetro “tamaño de la ventana” del MACD .....	170
Figura 68.- Resultados del parámetro “tamaño de la ventana” del Estocástico .....	170
Figura 69.- Evaluaciones del procesamiento del 1 al 10. Gráfico a: ciclo de vida de las soluciones encontradas. Gráfico b: beneficio final obtenido por las soluciones en ese intervalo. Gráfico c: total de operaciones realizadas por las soluciones a su cierre.....	174
Figura 70.- Resumen de resultados obtenidos por las soluciones en cada procesamiento en media. Gráfico a: Número de soluciones encontradas. Gráfico b: beneficio obtenido. Gráfico c: total de operaciones. ....	175
Figura 71.- Resultados para las estrategias referentes al número de soluciones encontradas y la actividad. ....	178
Figura 72.- Resultados para las estrategias referentes al beneficio total y al número de operaciones realizadas.....	178
Figura 73.- Resultados para las estrategias referentes al promedio de beneficio por operación conseguido .....	179
Figura 74.- Resultados obtenidos frente a los parámetros 1 y 2 del MACD. ....	180
Figura 75.- Resultados obtenidos frente a los parámetros 1 y 3 del MACD. ....	181
Figura 76.- Resultados obtenidos frente a los parámetros 2 y 3 del MACD. ....	181
Figura 77.- Resultados obtenidos frente a los parámetros MACD <sub>pa</sub> y MACD <sub>pb</sub> del MACD ....	182
Figura 78.- Resultados obtenidos frente a los parámetros 1 y 2 del Estocástico .....	182
Figura 79.- Resultados obtenidos frente a los parámetros 1 y 3 del Estocástico .....	183
Figura 80.- Resultados obtenidos frente a los parámetros 2 y 3 del Estocástico .....	183
Figura 81.- Resultados obtenidos frente a los parámetros estocasticopa y estocasticopb del Estocástico.....	184
Figura 82.- Resultados obtenidos frente a los parámetros “stop-loss” y “take-profit” .....	184
Figura 83.- Resultados obtenidos frente a los parámetros de Ventana MACD y Ventana del Estocástico.....	185
Figura 84.- Resultados para las estrategias referentes al número de soluciones encontradas y actividad. ....	186
Figura 85.- Resultados para las estrategias referentes al beneficio total y al número de operaciones realizadas.....	186
Figura 86.- Resultados para las estrategias referentes al promedio de beneficio por operación conseguido .....	187
Figura 87.- Resultados obtenidos frente a los parámetros 1 y 2 del MACD. ....	188
Figura 88.- Resultados obtenidos frente a los parámetros 1 y 3 del MACD. ....	189
Figura 89.- Resultados obtenidos frente a los parámetros 2 y 3 del MACD. ....	189
Figura 90.- Resultados obtenidos frente a los parámetros MACD <sub>pa</sub> y MACD <sub>pb</sub> del MACD .....	190
Figura 91.- Resultados obtenidos frente a los parámetros 1 y 2 del Estocástico .....	190
Figura 92.- Resultados obtenidos frente a los parámetros 1 y 3 del Estocástico .....	191
Figura 93.- Resultados obtenidos frente a los parámetros 2 y 3 del Estocástico .....	191
Figura 94.- Resultados obtenidos frente a los parámetros estocasticopa y estocasticopb del Estocástico.....	192
Figura 95.- Resultados obtenidos frente a los parámetros “stop-loss” y “take-profit” .....	192
Figura 96.- Resultados obtenidos frente a los parámetros de Ventana MACD y Ventana del Estocástico.....	193

Figura 97.- Resultados para las estrategias referentes al número de soluciones encontradas y actividad. ....	194
Figura 98.- Resultados para las estrategias referentes al beneficio total y número de operaciones realizadas.....	194
Figura 99.- Resultados para las estrategias referentes al promedio de beneficio por operación conseguido .....	195
Figura 100.- Resultados obtenidos frente a los parámetros 1 y 2 del MACD. ....	196
Figura 101.- Resultados obtenidos frente a los parámetros 1 y 3 del MACD. ....	197
Figura 102.- Resultados obtenidos frente a los parámetros 2 y 3 del MACD. ....	197
Figura 103.- Resultados obtenidos frente a los parámetros MACD <sub>pa</sub> y MACD <sub>pb</sub> del MACD ..	198
Figura 104.- Resultados obtenidos frente a los parámetros 1 y 2 del Estocástico .....	198
Figura 105.- Resultados obtenidos frente a los parámetros 1 y 3 del Estocástico .....	199
Figura 106.- Resultados obtenidos frente a los parámetros 2 y 3 del Estocástico .....	199
Figura 107.- Resultados obtenidos frente a los parámetros estocastico <sub>pa</sub> y estocastico <sub>pb</sub> del Estocástico.....	200
Figura 108.- Resultados obtenidos frente a los parámetros “stop-loss” y “take-profit” .....	200
Figura 109.- Resultados obtenidos frente a los parámetros de Ventana MACD y Ventana del Estocástico.....	201
Figura 110.- Beneficio obtenido por las distintas estrategias para conjunto 1 .....	202
Figura 111.- Beneficio obtenido por las distintas estrategias para conjunto 2 .....	203
Figura 112.- Beneficio obtenido por las distintas estrategias para conjunto 3 .....	203
Figura 113. - Multiobjective Pareto Front .....	256
Figura 114. - System Architecture.....	257
Figure 115. - The benefit to the strategies in the set 1.....	261
Figure 116. - The benefit to the strategies in the set 2.....	261
Figure 117. - The benefit to the strategies in the set 3.....	262

## ÍNDICE DE TABLAS

Tabla 1.- Tipo de cambio de las principales monedas Agosto 2009 .....	45
Tabla 2.- Cruce binario simulado $r=0.4$ , $\eta = 1(\beta = 1.27)$ . .....	85
Tabla 3.- Coste computacional de los diferentes operadores de selección.....	89
Tabla 4.- Ordenes de entrada según las señales generadas por los indicadores.....	111
Tabla 5.- Señales de cierre para ordenes abiertas. ....	111
Tabla 6.- Parámetros de una orden.....	112
Tabla 7.- Criterios para la generación de señales. ....	113
Tabla 8.- Detalle Criterios del Estocástico. ....	115
Tabla 9.- Rentabilidad media de la estrategia en el periodo 2001-2012. ....	116
Tabla 10.- Factor de beneficio semanal. ....	117
Tabla 11.- Parámetros MACD.....	118
Tabla 12.- Parámetros estocástico .....	119
Tabla 13.- Gen completo con la especificación de cada parámetro. ....	119
Tabla 14.- Valores de los parámetros del Gen. ....	119
Tabla 15.- Pérdida de capital en función del número de operaciones fallidas. ....	125
Tabla 16.- Resumen de tendencias para el conjunto de datos. ....	128
Tabla 17.- Resumen de tendencias para el conjunto de datos. ....	128
Tabla 18.- Resumen de los mejores ratios por ventana e intervalo de confiabilidad.....	130
Tabla 19.- Número de operaciones.....	131
Tabla 20.- Beneficio sin spread .....	131
Tabla 21.- Estimación de ganancias con spread.....	131
Tabla 22.- Beneficios en “pips” con spread.....	131
Tabla 23.- Configuración del algoritmo evolutivo. ....	139
Tabla 24.- Evaluación de los resultados obtenidos para las distintas métricas para el conjunto de datos 1.....	141
Tabla 25.- Resultados de los distintos algoritmos para el Conjunto de datos 2 .....	143
Tabla 26.- Resultados de los distintos algoritmos para el Conjunto de datos 3 .....	145
Tabla 27.- Valores de la optimización multi-objetivo sin grados de libertad (Comparativa 1). ..	176
Tabla 28.- Valores de la optimización multi-objetivo con grados de libertad en los parámetros del MACD (Comparativa 2).....	177
Tabla 29.- Valores de la optimización multi-objetivo con grados de libertad en los parámetros del Estocástico (Comparativa 3).....	177
Tabla 30.- Valores de la optimización multi-objetivo con grados de libertad para los parámetros de ambos indicadores (Comparativa 4). ....	177
Tabla 31.- Valores de la optimización multi-objetivo con todos los grados de libertad (Comparativa 5).....	177
Tabla 32.- Resumen del promedio de los datos obtenidos para todas las configuraciones del conjunto 1 .....	179
Tabla 33.- Resumen de la desviación típica de los datos obtenidos para todas las configuraciones del conjunto 1.....	179
Tabla 34.- Resumen del promedio y desviación típica de los datos obtenidos para todas las configuraciones. El valor mostrado es el correspondiente a $P(T \leq t)$ dos colas.....	180

---

Tabla 35.- Resumen del promedio de los datos obtenidos para todas las configuraciones del conjunto 1 .....	187
Tabla 36.- Resumen de la desviación típica de los datos obtenidos para todas las configuraciones del conjunto 1.....	187
Tabla 37.- Resumen del promedio y desviación típica de los datos obtenidos para todas las configuraciones. El valor mostrado es el correspondiente a P ( $T \leq t$ ) dos colas.....	188
Tabla 38.- Resumen del promedio de los datos obtenidos para todas las configuraciones del conjunto 3 .....	195
Tabla 39.- Resumen de la desviación típica de los datos obtenidos para todas las configuraciones del conjunto 3.....	195
Tabla 40.- Resumen del promedio y desviación típica de los datos obtenidos para todas las configuraciones. El valor mostrado es el correspondiente a P ( $T \leq t$ ) dos colas.....	196
Tabla 41.- Resumen de la ganancia promedio obtenida para una única solución .....	201
Tabla 42.- Resumen de la ganancia obtenida para la estrategia "Buy & Hold".....	202
Tabla 43.- Resumen de la ganancia obtenida para el frente de Pareto.....	202
Table 44. - Each parameter specification of the complete gene. ....	258
Table 45. The values of the parameters of the Gene.....	258
Table 46. - Summary of the obtained average gain for a single solution .....	260
Table 47. - Summary of the gain for the "Buy & Hold" strategy.....	260
Table 48. - Summary of the gain to the Pareto front strategy.....	261



## LISTA DE ACRONIMOS

<b>AE (EA)</b>	Algoritmo Evolutivo (Evolutionary Algorithm)
<b>AT</b>	Análisis Técnico
<b>BIS</b>	Banco de Pagos Internacionales (Bank for International Settlements)
<b>DJIA</b>	Dow Jones Industrial Average
<b>GA</b>	Algoritmo genético (Genetic Algorithm)
<b>GP</b>	Programación genética (Genetic Programming)
<b>HC</b>	Algoritmo de ascenso a la colina (Hill Climbing)
<b>HME</b>	Hipótesis de los Mercados Eficientes
<b>IT</b>	Indicador Técnico
<b>MA</b>	Algoritmo memético (Memetic Algorithm)
<b>MACD</b>	Convergencia / Divergencia del promedio móvil ( <b><i>Moving Average Convergence Divergence</i></b> )
<b>MME</b>	Media Móvil Exponencial
<b>MOEA</b>	Algoritmo evolutivo multi-objetivo (Multi-Objective Evolutionary Algorithm)
<b>MOGA</b>	Algoritmo genético multi-objetivo (Multi-Objective Genetic Algorithm)
<b>PIP</b>	La variación mínima que puede ocurrir en el precio de cotización de una divisa
<b>TWR</b>	Riqueza relativa ("Terminal Wealth Relative")





**Introducción**

**Objetivos de la tesis**

**Estructura de la tesis**

---



## Introducción

El proceso económico es el conjunto de actividades económicas que realizan los hombres con el fin de obtener los medios que le permitan satisfacer sus necesidades. Éste es realizado en sociedad y es un proceso continuo e interrelacionado que se agrupa en cinco fases: producción, circulación, distribución, consumo e inversión. Por tanto, éste puede ser simplemente la compra-venta de un producto o servicio. En este trabajo los procesos económicos analizados se refieren a la operativa en los mercados financieros internacionales y más concretamente a los relacionados con el mercado de divisas. El mecanismo que utilizan los agentes para evaluar sus expectativas y tomar sus decisiones es extremadamente complejo debido a la gran cantidad de variables posibles, y a la limitación temporal para definirlas. Por otra parte, los algoritmos evolutivos son métodos de optimización y búsqueda de soluciones utilizados principalmente en problemas con espacios de búsqueda extensos y no lineales, en donde otros métodos no son capaces de encontrar soluciones en un tiempo razonable. Por tanto, el objetivo es encontrar una técnica multiobjetivo que permita generar soluciones en estos mercados a partir del uso de estos algoritmos.

El mercado de divisas (también conocido como “Forex”, abreviatura del término inglés “Foreign Exchange”) es un mercado mundial y descentralizado en el que se negocian divisas. Este mercado nació con la idea de facilitar el comercio internacional, pero en la actualidad el total de operaciones en moneda extranjera que se deben a operaciones internacionales de bienes y servicios representan un porcentaje casi residual, debiéndose la mayoría de las mismas a compraventa de activos financieros. En consecuencia, este mercado es bastante independiente de las operaciones comerciales reales y las diferencias entre el precio de dos monedas no pueden explicarse de forma exclusiva por las variaciones de los flujos comerciales. El volumen de transacciones diario es enorme, aproximadamente de 5 billones de dólares estadounidenses (USD). En este mercado hay un conjunto de pares de divisas que son las que más se comercian: eur (euro)/usd (USA dólar), yen (yen japonés)/usd, usd/chf (francos suizos), gbp (libras esterlinas)/usd, gbp/eur, representando el noventa por ciento de las operaciones que se realizan. En las últimas décadas han desaparecido un gran número de monedas, por la creación de otras, como en el caso del euro, o simplemente por la sustitución de la nacional por otra internacional más segura y fiable.

Por otra parte, las políticas monetarias de los distintos países hacen que los valores de los pares varíen en mayor o menor medida, en función de lo que se negocie dicho par en el mercado. En pares donde la negociación es escasa, un giro brusco en la política monetaria puede conllevar una variación muy grande en el cambio. Un ejemplo del efecto que estas estrategias pueden tener se observa en la actual política monetaria expansiva de los Estados Unidos, con la puesta en circulación de ochenta y cinco mil millones de dólares mensuales. Ésto hace que el precio del dólar se devalúe con respecto al resto de monedas. Por tanto, la tendencia de este mercado a medio y largo plazo está relacionada con la política monetaria. Existen otros factores, como son la evolución de los precios, el número de parados, las exportaciones, etc..., que hacen que las autoridades monetarias determinen el tipo de política a seguir. Ésto hace que sea el análisis fundamental el que determine las acciones a realizar por parte de los inversores a medio y largo plazo.

En el corto plazo, el estudio de las predicciones se agrupa en dos grandes técnicas: Las Cuantitativas, que se basan en la realización de modelos estadísticos como ARIMA [Uriel85], ANOVA [Peña89], modelos de autoregresión, etc., y el Análisis Técnico, que estudia las series temporales de precios a través de un conjunto de indicadores matemáticos. Este trabajo se circunscribe en su aspecto teórico a la disciplina del análisis técnico y, por tanto, a la generación de una herramienta para la toma de decisiones en el mercado de divisas a corto plazo. No solamente se ha realizado una herramienta de inversión, sino que se ha implementado una novedosa técnica multiobjetivo. Está trabaja con un archivo externo en el que algoritmos evolutivos de distinta naturaleza (NSGA2, SPEA2, MoCell,...) pueden incorporar soluciones no dominadas en cualquier instante para generar señales de compra o venta en el Mercado. Esta aproximación permite aprovechar las capacidades de todas las soluciones generadas y en caso de que debido al dinamismo del sistema, no se generen soluciones no dominadas mediante una de las técnicas, generarlas con otra.

La Hipótesis del mercado eficiente, desarrollada por Fama [Fama70] en su versión más débil (ver apartado 1.2.2.1), indica que no es posible obtener arbitraje en el corto plazo, ya que la nueva información se introduce en los precios de forma automática e instantánea. En este trabajo, se observa que la generación del precio para un par de divisas es un proceso dinámico que requiere del análisis continuo de los datos cada vez que estos se producen. Es decir, no es instantáneo. El arbitraje se genera en la dinámica del cambio, desde la reacción inicial hasta su estabilización en el nuevo precio. Por tanto, una de las características más importantes de un sistema de *“trading”* en tiempo real es el análisis de la dinámica de la operativa *“tick”* a *“tick”*, operación a operación, para observar en cada fotograma cómo se modelan los precios. Cuando analizamos una ventana de quince minutos eur/usd, lo que se puede observar es el comportamiento de los precios en esa escala temporal. Es posible que en esos minutos el sistema haya podido añadir la información a los precios, pero en ese tiempo se han producido un número de operaciones, entre trescientas y cuatrocientas en un mercado normal, que son las que han modelado el precio hasta su valor actual. El sistema de *“trading”* debe advertir la nueva dinámica generada, y para ello utilizaremos el análisis técnico y más concretamente los indicadores técnicos, en este caso el MACD y el estocástico para obtener un beneficio del mercado.

La computación evolutiva, y en especial los algoritmos evolutivos, nos permiten encontrar indicadores optimizados para un mercado y ventana temporal concreta. En la actualidad ya existen herramientas que hacen uso de estos conceptos con mayor o menor éxito. En este trabajo se intenta dar un paso más, permitiendo que sea el propio algoritmo el que determine los parámetros óptimos de los indicadores y la escala temporal donde alcanza el mejor rendimiento. Es un cambio en el paradigma del análisis técnico, ya que no es el inversor el que escoge el marco temporal y estudia las posibilidades de inversión. Ahora es el indicador el que determina los mejores marcos de inversión para la estrategia seleccionada. Es decir, será el propio indicador el que en función del análisis de la información le indique al inversor la escala temporal en la que debe realizar su inversión. Esto es un salto cuantitativo y cualitativo importante, ya que en otras aproximaciones algunas estrategias eran desechadas por el hecho de que no eran aplicadas en la ventana temporal adecuada.

Además, el problema del inversor no es el simple hecho de maximizar los beneficios, sino que trata de minimizar los riesgos y los costes de la operativa. Por tanto, estamos ante un problema multiobjetivo en el que una estrategia determinada puede tener distintas soluciones equivalentes en función de unos intereses particulares. Es decir, podemos encontrar un inversor que desea minimizar los costes y maximizar los beneficios, y otro que desea minimizar los riesgos aunque los costes sean mayores. Esto hace que la herramienta determine ambas estrategias, la global y la específica del *“trading”*. La técnica multiobjetivo desarrollada incluye esta nueva aportación, evaluando el conjunto completo de soluciones y permitiendo seleccionar distintos perfiles de riesgo, coste y beneficio.

Otro elemento fundamental para el inversor es la gestión de la cartera y la diversificación de la misma. Las empresas internacionales necesitan tener su capital en forma líquida, en divisas, para proceder a la compra-venta de productos en los mercados internacionales. Ello supone que de forma indirecta éstas tienen una inversión en el mercado de divisas, sin embargo no tienen diversificación alguna. Ésta herramienta supondría la creación de un conjunto de agentes con distintos objetivos de beneficio-riesgo, que permitirían la diversificación de la inversión dentro del marco de la propia divisa. Ésto supondría la capacidad de mantener el capital líquido estable sin la necesidad de recurrir a seguros y comisiones que merman sus beneficios de forma considerable.

También hay otra aportación fundamental en este trabajo, que es el cálculo en tiempo real de la gestión del capital. Cada solución generada por el algoritmo evolutivo incorpora su propio desarrollo de gestión de capital, lo que hace que en conjunto el sistema acote los riesgos de la operativa real.

Por último, indicar que la arquitectura y el diseño de la herramienta permiten trabajar con cualquier conjunto de indicadores, algoritmos evolutivos y en cualquier mercado, aunque en este trabajo todos los experimentos realizados y los resultados obtenidos son debidos a la operativa en el mercado de divisas y para el par euro-dólar. También permite trabajar con cualquier bróker online en tiempo real del mercado.

## Objetivos de la tesis

Por todo lo anteriormente expuesto nos hemos propuesto en este trabajo de investigación los siguientes objetivos:

1. ***Desarrollar una técnica multiobjetivo de toma de decisiones de inversión en los mercados financieros, más concretamente en el mercado de divisas, utilizando AEs. Se implementará una herramienta que validará las bases teóricas expuestas.*** Este tipo de herramientas se denominan sistemas de “trading”. La realización de dichos sistemas implica un gran esfuerzo tanto de tiempo como económico. En esta tesis se implementará un sistema de “trading” en tiempo real completo basado en AEs.
2. ***La herramienta podrá incorporar cualquier conjunto de indicadores técnicos, así como realizar todo tipo de estrategia.*** En este trabajo se va a utilizar una única estrategia, con dos indicadores concretos. Esta estrategia determina un conjunto de soluciones, las cuales se basan en un entorno multiobjetivo y que determinarán el nivel de riesgo, disminución de los costes y la maximización de la ganancia en la operativa final.
3. ***El sistema operará en tiempo real con el conjunto de datos del mercado de divisas. Se utilizarán datos reales para su validación.***
4. ***Estudiar la aplicación de distintos Aes para la realización de “trading”.*** Se pretende analizar las características que podrá implementar la aplicación desarrollada.
5. ***Se analizará si el tiempo de cómputo es adecuado para el mercado estudiado. También se examinará la escalabilidad del sistema a otros mercados.***

1. ***El desarrollo de una técnica multiobjetivo para la toma de decisiones en los mercados internacionales de divisas requiere de la utilización de unas bases teóricas y prácticas muy sólidas.*** La computación evolutiva se ha desarrollado considerablemente en las últimas décadas, debido a la utilización de ordenadores cada vez más potentes que han permitido el desarrollo de nuevas técnicas y herramientas. Este avance se ha producido tanto en el análisis cuantitativo como en el técnico. En el primero, con la generación de nuevos modelos estadísticos como ARIMA [Uriel85], ANOVA [Peña89], modelos de autorregresión, etc. así como nuevas herramientas que permiten trabajar con dichos modelos de predicción [Maravall96].

Por otra parte, el análisis técnico ha avanzado enormemente con la generación de indicadores técnicos muy complejos y con herramientas que permiten la aplicación de éstos en tiempo real sobre un bróker online. Eso ha permitido que el ajuste de los precios sea cada vez más instantáneo, haciendo que los arbitrajes tradicionales vayan desapareciendo y que el análisis de la información se produzca “tick” a “tick”, es decir, operación a operación. Ésto también ha permitido que los brokers salgan del parqué y puedan trabajar desde cualquier parte del mundo en tiempo real.

La aplicación final se compone de los siguientes módulos:

- a. **Gestor extractor de datos:** extrae, procesa y almacena los datos correspondientes a la serie temporal de precios.

- b. **Gestor de soluciones:** aplica los algoritmos evolutivos a la estrategia planteada para la obtención de soluciones óptimas. Éste se ha creado de manera configurable para operar con los distintos algoritmos evolutivos utilizados en este trabajo.
- c. **Gestor de expertos:** las soluciones obtenidas anteriormente son evaluadas para una gestión de capital óptima. A partir de este momento éstas se denominarán expertos. Éste módulo tiene un doble objetivo, gestionar el capital y, por otra parte, monitorizar los expertos detectando nuevas señales para cada nuevo precio. Cuando una señal se produce se ejecuta una orden que será tratada por el bróker en tiempo real. Toda la información que se genera en este proceso es almacenada para su posterior procesamiento en la gestión de capital.
- d. **Gestor bróker:** gestiona las operaciones en tiempo real con la cuenta del bróker online. Es independiente del mismo y podría funcionar en casi todos los bróker internacionales actuales. Es el lugar donde se abren y cierran las operaciones y donde se gestiona el “stop-loss” dinámico. Éste está sincronizado en todo momento con el gestor de expertos.

2. ***La herramienta podrá incorporar múltiples estrategias a partir de la selección de distintos indicadores.*** En este trabajo, la estrategia está basada en dos conceptos teóricos como son la tendencia y el momento. Por ello, se han seleccionado dos indicadores: El MACD, que será el seguidor de la tendencia, y el Estocástico que monitorizará la velocidad del precio o el momentum. Los valores apropiados de los mismos serán seleccionados en función de los datos reales que se vayan produciendo en el mercado. Por otra parte, hay un aspecto fundamental y es la selección del marco temporal en el que la estrategia desarrollará el mejor rendimiento posible. Para ello se han incorporado un conjunto de parámetros que permitan su selección. Por último, también se deben incluir todas aquellas variables pertenecientes al ámbito de la operativa, como son el “stop-loss”, el “take-profit” o el “trailing-stop”. Todos los elementos anteriores conformarán los expertos que llevarán a cabo la operativa real. Éstos son generados para desarrollar los objetivos propuestos; minimizar riesgos y costes, maximizar beneficios y diversificar la inversión.

Además, se desarrollará un algoritmo para la gestión de capital de la cuenta, y para que los expertos entren en el mercado con una gestión de la cartera adecuada.

3. **Se validará la herramienta mediante datos reales.** La herramienta, junto con sus fundamentos teóricos, será validada con el conjunto de datos históricos, y sus resultados serán analizados en función de un conjunto de variables estadísticas. Por otro lado, se compararán los resultados con los obtenidos por otros métodos para observar la mejora conseguida en el proceso de optimización propuesto en esta tesis.
4. ***Se realizará una revisión previa de la aplicación de los algoritmos evolutivos en los mercados financieros.*** De esta forma, se podrán contrastar las distintas líneas de



investigación, e identificar posibles mejoras en la herramienta desarrollada. Se insistirá fundamentalmente en el campo de las inversiones en el sistema financiero internacional, concretamente, en el mercado de divisas. El análisis técnico es una de las técnicas más utilizadas en la toma de decisiones de inversión en los mercados internacionales de divisas. Por ello, se analizarán sus posibilidades actuales y de optimización futuras.

5. **El tiempo de cómputo en un sistema de tiempo real es fundamental. Es este trabajo se analizará como los cálculos se efectúan en un tiempo adecuado.** Además se estudiará la escalabilidad del sistema a otros mercados.

## Estructura de la tesis

Esta tesis está organizada de la siguiente manera.

En el **primer capítulo** se trata brevemente la historia del mercado de divisas, haciendo especial hincapié en los siglos XIX y XX, cuando se da origen al mercado de divisas como se conoce actualmente. Posteriormente se tratan conceptos fundamentales como son los tipos de cambio y sus variaciones. Estos mercados están influenciados por las políticas monetarias internacionales, y por ello se tratan brevemente las herramientas básicas a su alcance. A continuación, también se menciona aunque brevemente, las principales escuelas y líneas de pensamiento en esta disciplina. En los siguientes apartados se tratarán las técnicas de análisis cuantitativo y técnico para la predicción en los mercados financieros. En este capítulo también se justifica la elección del análisis técnico frente al análisis univariante. También se realiza una revisión de la literatura en lo que corresponde a la aplicación de la computación evolutiva y especialmente de los AES en la economía. También se estudian los indicadores técnicos que se han aplicado en éste trabajo. Al final del capítulo se incluye un apartado de definiciones de términos asociados al mercado de divisas.

En el **segundo capítulo** se tratan las técnicas heurísticas que guiarán al proceso de optimización multi-objetivo, y se presentan las definiciones fundamentales que son la base teórica de los problemas de optimización. Además se desarrolla el concepto de complejidad computaciones y algoritmos de optimización para posteriormente justificar la complejidad del problema y con ello la posibilidad de usar AEs para la resolución del mismo. También se realiza una aproximación a los métodos clásicos para la optimización multiobjetivo.

En el **tercer capítulo** se revisan los conceptos teóricos básicos sobre algoritmos evolutivos necesarios para desarrollar la aplicación de gestión de estrategias de “trading” en el mercado de divisas. Inicialmente se trata de forma breve su historia y después se repasan los fundamentos y terminología básica de los algoritmos evolutivos.

El **capítulo cuatro** explica la arquitectura del sistema desarrollado y de sus componentes. Se indica la selección de los distintos parámetros y de los objetivos planteados para el problema de optimización multiobjetivo. Se tratan los problemas de la selección del marco temporal y de los datos, elementos clave para el trabajo con algoritmos evolutivos. También se incluye un estudio por el cual se ha seleccionado un algoritmo evolutivo concreto y los parámetros del mismo.

El **capítulo quinto** recoge los resultados de las experimentaciones realizadas que justifican la utilidad de la herramienta y la mejora generada con respecto a otras. En concreto, se muestran los resultados de la comparación de los algoritmos SPEAII y NSGAII para el conjunto de datos históricos propuesto. La media del beneficio para el número total de experimentos para cada uno de los tres grupos de datos y del total. El comportamiento temporal del frente de Pareto de soluciones activas. Y por último, una comparación con otros modelos propuestos por la literatura.

El **capítulo sexto** incluye las conclusiones del trabajo y presenta futuras líneas de investigación.

El **capítulo séptimo** presenta las publicaciones científicas a las que ha dado lugar este trabajo y el **capítulo octavo** recoge la bibliografía utilizada en ésta tesis.

## **1. Conceptos Económicos**

---

**1.1 Economía y mercados de divisas**

**1.2 Predicción en mercados financieros**

**1.3 Indicadores técnicos**

**1.4 Definiciones**

**1.5 Conclusiones y resumen**

---

En este capítulo se realiza una introducción a los conceptos económicos fundamentales en el mercado de divisas, necesarios para comprender el trabajo teórico y empírico realizado en la presente tesis. Mercado de divisas, tipos de cambio, variaciones en el tipo de cambio, política monetaria, son conceptos que son mencionados con continuidad a lo largo de este trabajo. Procede, por tanto, presentarlos adecuadamente y situarlos en el contexto que corresponde.

Posteriormente se incluye una breve introducción a la predicción en los mercados financieros, más concretamente a la realizada por el análisis cuantitativo y técnico. También se expone una revisión de los trabajos más importantes en el área de la computación evolutiva y la economía.

Para finalizar, se explican los indicadores técnicos implementados en este trabajo y se realiza un breve resumen del mismo, junto con las conclusiones obtenidas.

## 1.1.- Economía y mercados de divisas

En este primer apartado se realiza una breve introducción histórica sobre la evolución del mercado de divisas en los siglos XX y XXI. Esto nos permite observar su complejidad y cómo ha sido su conformación hasta la fecha actual.

Los primeros intercambios comerciales que se realizaron en la historia fueron los trueques. Estos comprendían todo tipo de productos: Piel, metales, alimentos, personas, animales etc. El problema de los trueques es que eran muy ineficientes, ya que dependían de la demanda de cada individuo en cada momento. Por ello, aparecieron ciertos bienes que eran más fácilmente intercambiables que otros. Éstos tenían básicamente tres cualidades; ser fácilmente transportables, intercambiables y no perecederos. Los recursos con esta capacidad eran objeto de una gran demanda, no tanto para su consumo, sino por su liquidez y capacidad de almacenamiento. Este tipo de capitales se denominó dinero, y representa la riqueza no consumida. Éste permite el pago de bienes y servicios y de cualquier tipo de obligación, sirviendo de intercambio común y generalizado dentro de una sociedad. Inicialmente fueron muchos los que compitieron por este papel preponderante, aunque finalmente se impuso el oro, las razones fueron las siguientes: Es transportable, divisible, homogéneo, duradero y difícil de falsificar.

Por tanto, el dinero surgió del mercado y después las leyes lo regularon. Los gobiernos se esforzaron por obtener el monopolio de su emisión y así empezaron a acuñarse las primeras monedas. El valor de éstas estaba determinado por la cantidad de metal en su composición, generalmente oro y plata. Posteriormente y debido al peso de éstas, empezaron a utilizarse unas notas de papel que otorgaban al portador la posesión de cierta cantidad de oro depositada en cierto lugar. Los bancos comerciales de todo el mundo emitían estos billetes. Hasta las primeras décadas del siglo XIX casi todos los países empleaban un sistema basado en la emisión de monedas o billetes respaldado por estos dos metales. En 1821 el Reino Unido fue el primer país en utilizar únicamente el patrón oro. Posteriormente fueron uniéndose otros como Alemania (1875), Francia (1878), Estados Unidos (1879), Rusia y Japón (1897).

La estabilidad basada en este patrón oro permitió mantener controlada la inflación y el tipo de cambio, y concedió un gran crecimiento del comercio internacional desde las guerras napoleónicas hasta la primera guerra mundial.

A finales del XIX nació el Banco de Inglaterra, tal y como lo conocemos hoy en día, ya que su creación inicial fue realizada por el rey William III en 1694. En noviembre de 1910, en la isla de Jekyll, se creó el sistema de la Reserva Federal (Banco Central Americano), el cual entra a funcionar por una ley del Congreso Americano el 23 de diciembre de 1913. La FED es un monopolio de propiedad privada sobre el cual el gobierno no tiene ningún control, aunque es presentado como si estuviera a su cargo. Es fácil pensarlo ya que los presidentes de la FED y siete de los doce gobernadores son nombrados por el presidente y aprobados por el Senado. Como tal, la Reserva Federal es una especie de entidad gubernamental, pero el hecho es que el Sistema es de propiedad privada con fines de beneficio privado como cualquier otra empresa. Tiene accionistas como otras corporaciones públicas, que reciben un 6% de intereses libres de riesgo cada año sobre su participación en el capital. Entre sus mayores accionistas podemos encontrar sus creadores, las familias Morgan, Rockefeller y Rothschild. [Greider89]

La creación de la FED representa un hito fundamental para entender la economía mundial en el siglo XX y XXI. En primer lugar, ésta recibió el mandato legal para poseer el mayor poder de cualquier institución de un país, el de gestionar su política monetaria y crear y controlar su suministro de dinero. El sistema que se creó se conoce como *“triple invertida de la isla de Jekyll”*. La FED emite billetes respaldado en sus reservas en oro. Estos billetes se sostienen sobre una cantidad de oro inferior. Los bancos nacionales ofrecían depósitos a sus clientes respaldados en estos billetes de la reserva y, a continuación, los bancos regionales gestionaban los créditos a los clientes comerciales. Esto hizo que por primera vez se pusieran en circulación dinero no respaldado en oro, sino en la confianza del mercado en la buena gestión de los bancos centrales. Estas divisas se conocen con el nombre de *“moneda fiduciaria”*, del latín *“fides”*, confianza. En pocas palabras, la FED tiene el poder de crear dinero de la nada.

Al finalizar la I Guerra Mundial los Estados Unidos se habían convertido en el primer país acreedor del mundo. Los activos exteriores netos de Estados Unidos pasaron de 2.500 millones de dólares en 1914 a 5.500 millones de dólares en 1919 [Triefin64]. En el Tratado de Versalles (1919) que puso fin a la Gran Guerra, se consideró a Alemania culpable del conflicto y se le obligó a indemnizar a los aliados por sus pérdidas de guerra, pagando «reparaciones». En la Conferencia de Spa (junio de 1920) se fijaron los porcentajes, Francia se beneficiaría del 52% y el Reino Unido del 22%. En abril de 1921 se fijó la cuantía en 132.000 millones de marcos oro a pagar en los siguientes veinticinco años.

Después de la finalización de la primera guerra mundial se celebró en 1922 la conferencia de Génova, donde se reunieron 34 países en búsqueda de acuerdos para la reconstrucción del comercio y el sistema financiero europeo. Aquí se adoptó un sistema de pirámide invertida, parecida a la de la isla de Jekyll. Los dólares se sostenían sobre una cantidad de oro inferior, sobre ésta se apoyaban las libras y finalmente el resto de las divisas lo hacían sobre ésta.

Las resoluciones del Pacto de Génova establecían un sistema monetario que permitía a los gobiernos gestionar la cantidad de dinero y mantener "estable" el poder adquisitivo del mismo, evitando "grandes" fluctuaciones en el precio del oro. Éste permitiría a los estados regular las tasas de interés a través de operaciones de mercado abierto, y por tanto abrió la puerta a que los bancos centrales emitieran billetes no sólo contra oro, sino además contra divisas convertibles a oro y contra títulos públicos y privados. El patrón oro que castigaba al que emitía demasiados billetes había desaparecido. Ahora los bancos centrales emitían moneda según su criterio.

Esta situación proporcionaba una posición privilegiada y hegemónica al emisor de las divisas centrales del sistema. El Reino Unido y Estados Unidos fueron los mayores defensores de este sistema, en contra del Patrón Oro clásico [Brown40], y la libra esterlina y el dólar norteamericano terminarían por imponerse como «divisas internacionales». Esto hizo que aparecieran dos grandes centros financieros, Londres y Nueva York, que competían por el liderazgo financiero mundial.

A finales de 1922 Estados Unidos era acreedor sobre Europa por más de 9.000 millones de dólares, de los que más de 4.000 correspondían al Reino Unido y cerca de 3.000 a Francia. Estos dos países confiaban hacer frente a sus compromisos con lo recibido por las reparaciones de la guerra. Por otra parte, Francia había sido obligada a pagar cuantiosas reparaciones de guerra a Alemania tras el fin de la guerra franco-prusiana. Por todo ello, se exigió a Alemania el

cumplimiento de sus obligaciones internacionales y ante una primera negativa en 1923, Francia no dudaría en invadir la cuenca del Ruhr, provocando una fuerte reacción nacionalista en Alemania: «*Le Boche paiera*».

Para acometer la deuda, la economía alemana debía generar un excedente de recursos equivalente al 2-3% de su renta nacional y al 10-15% de sus ingresos por exportaciones. Sin embargo, Alemania mantuvo un elevado déficit fiscal hasta 1924, financiado por la emisión de dinero. Ésto, junto a la depreciación del tipo de cambio, provocó una hiperinflación sin precedentes. A finales de 1923 se emitieron billetes de hasta 50.000 millones de marcos y la huida del dinero forzó la aparición de formas diversas de trueque. Incluso se creó una nueva unidad monetaria, el rentenmark, que equivalía a 1 billón de marcos antiguos.

Los Estados Unidos de América, en un intento por estabilizar Alemania, diseñaron el denominado “*Plan Dawes*” (1924). Ésta volvió al patrón oro, se restableció el reichsmark y, con un crédito internacional de 800 millones de marcos, Alemania pudo hacer frente al primer pago de las reparaciones. Cinco años después, un nuevo plan norteamericano, el “*Plan Young*” (1929), fijaría nuevos plazos más amplios para el pago del resto de las reparaciones, pero éste fracasó debido a la depresión económica que hacía imposible conseguir que Alemania continuara los pagos por reparaciones y que el crédito norteamericano pudiera fluir.

Por otra parte, el Reino Unido veía crecer la competencia financiera norteamericana asentada en unas reservas de oro que eran cinco veces superiores a las británicas. En 1925 el Reino Unido restableció la convertibilidad de la libra en oro, lo que significaba revalorizar la Libra y conseguir que Londres siguiera siendo un gran centro financiero. Los intereses de la City habían conseguido imponerse sobrevalorando la Libra en un 10% [Moggridge72].

Por otro lado Francia, tremendamente afectada por la guerra, había abandonado la convertibilidad en 1914 y no pudo restaurarla hasta el 7 de agosto de 1926, cuando entró en un sistema de Patrón Cambios Oro. El tipo que se fijó el 22 de diciembre de 1926 hizo que la divisa francesa se devaluara en un 80% con respecto a su paridad antes de la guerra. Los especuladores jugaron entonces con la posibilidad de una revaluación, y compraron grandes cantidades de francos entregando oro y divisas a cambio. Entre 1925 y 1928 se centuplicaron las reservas de divisas y casi se duplicaron las reservas de oro del Banco de Francia.

Por entonces, treinta y cuatro países cubrían su emisión con oro y veinticinco habían adoptado el Patrón de Cambio en Oro, aunque sólo existían tres verdaderos «centros de oro»: Nueva York, Londres y París. Sin embargo, el sistema no iba a durar mucho. Desde finales de 1929 se extiende la sombra de la Gran Depresión por la economía norteamericana, y el mundo se verá abocado a una crisis sin precedentes por su duración y gravedad. El Reino Unido se vio afectado por los graves problemas en su Hacienda y balanza comercial. La desconfianza creció sobre la libra y se empezaron a hacer retiradas masivas de capitales. El 21 de septiembre de 1931, el Reino Unido tendría que abandonar el Patrón Oro, produciéndose en los siete meses siguientes una depreciación de la libra cercana al 40% de su valor frente al dólar.

Estados Unidos abandonaría el Patrón Oro el 20 de abril de 1933, con una depreciación próxima al 60%, quedando el tipo de cambio a 35 dólares la onza. En ese momento, muchos países del continente americano vincularon su moneda al dólar, formando un área de influencia muy importante.



En la Conferencia Económica Mundial de Londres, en junio-julio de 1933, El Reino Unido y Estados Unidos consideraron que la prioridad se centraba en la recuperación del nivel de actividad interna, y ello parecía oponerse a la estabilización del tipo de cambio. Sólo Francia mantuvo su apoyo al Patrón Oro y la cooperación internacional. Sin embargo, los especuladores entendieron que el Franco quedaba sobrevalorado y se inició una salida de capitales (oro y divisas) que terminaría con la salida del Franco del Patrón Oro en octubre de 1936. Previamente, el resto de los países del «bloque oro» habían tenido que irlo abandonando. Todos ellos habían sido empujados por la depresión económica, agravada por la ortodoxia monetaria impuesta a sus políticas económicas [Yeager76]. Por tanto, las décadas de 1920 y 1930 muestran la alternancia de sistemas de tipo de cambio fijo con tipos de cambio flotantes, en un contexto caracterizado por graves dificultades económicas a nivel internacional [García92].

Aun así, la estabilidad de los tipos de cambio siguió siendo uno de los objetivos más importantes a nivel internacional. Francia, el Reino Unido y los Estados Unidos firmaron un acuerdo el 25 de septiembre de 1936, estableciendo la convertibilidad de los billetes en oro entre bancos centrales y limitando la posibilidad de nuevas devaluaciones competitivas. Este acuerdo tripartito será un antecedente importante del sistema de Bretton Woods, diseñado ocho años más tarde. En cualquier caso, a finales de la década de 1930 la mayor parte de las monedas operaron en una flotación intervenida, creándose fondos de estabilización por doquier: la libra lo hizo desde 1932, el dólar desde enero de 1934, el franco tras la devaluación de 1936 y el marco estuvo sometido a un severo control de cambios desde julio de 1931.

Al final de la segunda guerra mundial, las potencias vencedoras se reunieron en la conferencia de Bretton Woods (1944) para diseñar un nuevo sistema monetario internacional: El denominado “*Plan White*”. Éste consistió en tres acuerdos fundamentales [Martínez70]:

- 1.- La creación del Fondo Monetario Internacional (FMI). El objetivo de ésta institución era describir una serie de reglas sobre la conducta de las políticas monetarias internacionales.
- 2.- La creación del Banco Mundial, para la financiación de proyectos de desarrollo.
- 3.- El sistema financiero internacional se redefinía con respecto a la conferencia de Génova, eliminando las libras de la pirámide. Por tanto, todo el sistema estaba basado en dólares.

Durante las décadas de los años 50 y 60 se hizo un esfuerzo por mantener el patrón oro-dólar pero no fue posible por los siguientes factores [López06]:

- 1.- La política monetaria expansiva y la creciente inflación de los Estados Unidos, relacionadas con la guerra del Vietnam.
- 2.- El creciente peso de las economías alemanas y japonesas y la demanda de sus respectivas monedas frente al dólar.
- 3.- El precio del oro seguía a 35\$ la onza, pero el coste marginal para conseguir una onza era creciente.
- 4.- Las fluctuaciones de algunas monedas extranjeras.

Debido a todos estos problemas, en agosto de 1971 el presidente Richard Nixon suspendió la convertibilidad del dólar con el oro. En un intento de salvar el sistema, las mayores potencias se reunieron en la conferencia de Washington en diciembre de 1971 y se firmó el siguiente acuerdo.

- 1.- El precio del oro se estableció en 38 dólares por onza.
- 2.- Cada uno de los países revaluó su moneda en un 10%.
- 3.- Se permitió una banda de fluctuación del 2,25%.

Pero estos acuerdos no fueron suficientes y en marzo de 1973 las monedas europeas y el yen japonés dejó la relación fija y pasaron a la libre fluctuación. Como dato, el precio actual de la onza de oro es de 1500 \$ por onza. La devaluación del dólar fue brutal, ésto provocó que todos los agentes económicos quisieran deshacerse de los dólares para comprar otros activos que no se devaluasen tan rápidamente, lo que hizo que el oro y el petróleo dispararan su precio en dólares. A esta crisis se la denominó “La crisis del petrolero” [Vidal04] cuando se debiera haber llamado “La crisis del dólar”.

Posteriormente en 1976 se celebró la conferencia de Jamaica, donde se realizó la segunda reforma del sistema monetario internacional. Básicamente ésta consistió en formalizar la fluctuación de las distintas monedas. Los cambios fueron publicados en detalle en el informe de los directores ejecutivos de 1976.

En mayo de 1990 se realizó una pequeña enmienda que incluía la suspensión del derecho de voto y de otros derechos de los países miembros que no cumplieran las obligaciones que les imponía el convenio.

En marzo de 1979 los países miembros de la Comunidad Económica Europea crearon el Sistema Monetario Europeo. Su objetivo era triple: conseguir la estabilidad económica, superar las repercusiones de la interdependencia de las economías de la UE y ayudar al proceso a largo plazo de la integración monetaria europea. Finalmente en 1999 once países europeos lanzaron la moneda única, que sustituyó a todas las monedas de los países participantes en el sistema. En enero de 2002 el euro empezó a circular y sustituyó a los billetes y monedas de los países que habían suscrito los acuerdos de Maastricht.

En mayo de 2004 se produjo la ampliación de la Unión Europea en 10 países, formando la unión de los 25. De éstos sólo Eslovenia, Malta, Chipre y Eslovaquia adoptaron el euro inicialmente. En 2012 se unieron lituana, Estonia, Bulgaria, Letonia, República Checa y Andorra, mientras que Rumanía y Hungría lo harán en el 2014.

En el actual contexto monetario internacional se puede apreciar un movimiento de simplificación en cuanto a la utilización de divisas; aparte de las cuatro principales monedas: El dólar, el euro, el yen y la libra, las demás divisas van tendiendo a obviarse o a desaparecer. Según el estudio del Banco de Pagos Internacionales, los cruces de monedas más negociados son: EUR/USD - 28%, USD/JPY - 14%, GBP/USD - 9%. El dólar estadounidense intervino en el 89% de las transacciones, seguido por el euro (37%), el yen (20%) y la libra esterlina (17%).

De hecho, el vicescanciller ruso Andrei Denisov y el presidente del Banco Popular Chino, Zhou Xiaochuan, han sugerido al director gerente del FMI, la creación de una moneda única basada en una canasta de monedas, controlada por el Fondo Monetario Internacional, como medio

para sustentar la estabilidad económica y financiera global. En Washington, el presidente de los Estados Unidos reiteró que no hay necesidad de introducir una nueva moneda global, ya que el dólar se fortaleció y los expertos consideran fuerte la economía estadounidense.

La crisis financiera ha acelerado la debilidad del dólar. China, India, Rusia y otros países exportadores de petróleo tienen gran parte de sus reservas en esta divisa por lo que, si sigue devaluándose, es posible que éstas se vean mermadas ampliamente y por ello buscan diversificar los riesgos con la compra de otras divisas, como el euro.

En el siglo XX Carl Menger, considerado fundador de la Escuela Austriaca de Economía, en su obra, principios de economía[Menger71], nos dejó una enseñanza que nunca se debería olvidar, y que citamos a continuación.

*“El dinero no es una cantidad que pueda generarse o imprimirse a partir de la nada y por decreto, sino una cualidad, la liquidez, que el mercado descubre en los bienes y en los activos”*

### **1.1.1.- El Mercado de Divisas**

El mercado de divisas podría considerarse como un mercado perfecto ya que existen muchos compradores y vendedores, el producto que se intercambia es homogéneo, y ningún agente que interviene en el mercado es capaz de modificar su precio. El producto que se comercia en este mercado es la divisa, que se intercambia por otras. Inicialmente nació con el objetivo de facilitar el flujo monetario que se deriva del comercio internacional. El volumen diario de transacciones ha crecido tanto que, en la actualidad, el total de operaciones en moneda extranjera que se debe a operaciones internacionales de bienes y servicios representan un porcentaje muy pequeño, debiéndose la mayoría de ellas a la compraventa de activos financieros. En consecuencia, este mercado es bastante independiente de las variaciones de los flujos comerciales reales, y está más influenciado por otras variables como pueden ser el crecimiento del PIB, la inflación, los tipos de interés o la balanza comercial, entre otras.

Las cotizaciones comienzan en Sídney, Tokio y Hong Kong, el denominado mercado asiático, y continúan con el europeo: Zúrich, Frankfurt y Londres, para finalizar con el americano: Nueva York, Chicago y Toronto. El mayor nivel de negocio se produce con el inicio del mercado americano a las 15:00 horas, horario de España.

Los agentes que participan en el mismo son los siguientes:

- 1.- Bancos internacionales y sus clientes: Éstos representan el corazón del mercado de divisas.
- 2.- Intermediarios no bancarios: Normalmente Sociedades y Agencias de Valores. Según el informe del Banco de Pagos Internacionales se les atribuye un 28% del volumen total de negociación.
- 3.- Brókeres de divisas: Compran y venden divisas a cambio de comisiones. Estos tienden a desaparecer, ya que el 90% de las transacciones se realizan de forma electrónica.
- 4.- Bancos Centrales: si el tipo de cambio es fijo, compran o venden su moneda para mantener la paridad, y si el tipo de cambio es variable, para mantener un tipo de cambio acorde a su política monetaria.

Todos estos agentes utilizan a la Sociedad de Telecomunicaciones Financieras Interbancarias Mundiales (SWIFT, por sus siglas en inglés) para llevar a cabo sus operaciones comerciales de forma rápida, segura y fiable. SWIFT es una institución sin ánimo de lucro que tiene su sede central en Bélgica y cuenta con oficinas en los principales centros financieros y mercados en desarrollo del mundo. Ésta es únicamente un transmisor de mensajes. No posee fondos ni gestiona cuentas en nombre de los clientes, ni tampoco almacena información financiera de forma permanente. Al actuar como transmisor, sirve de vehículo para los mensajes enviados entre dos instituciones financieras. Esta actividad implica el intercambio seguro de datos privados, al tiempo que se garantiza su confidencialidad e integridad.

Por otra parte, no todos los países tienen el mismo sistema de cambio. Éstos eligen el más adecuado conforme a su política monetaria. El FMI es el encargado de controlar los sistemas cambiarios, de forma que los países miembros no adopten sistemas de cambio que presenten ventajas comparativas injustas sobre otros países miembros. Básicamente existen los siguientes sistemas de cambio [Lopez06]:

1. Tipos Fijos.
  - Regímenes de cambio con otra moneda como referencia (dolarización formal).
  - Regímenes de cambio sin moneda de referencia (uniones monetarias).
  - Acuerdos de caja de conversión (currency Board).
2. Tipos Intermedios.
  - Acuerdo de tipo convencional: con una moneda o con una cesta.
  - Tipos fijos: ajustes forward y backward.
  - Tipos fijos en bandas horizontales.
  - Tipos de cambio fijos dentro de bandas ajustables: forward y backward.
3. Tipos Libres.
  - Gestiones fuertes u otras flotaciones dirigidas sin objetivos señalizados.
  - Flotación libre.

La tendencia actual es ir hacia sistemas de cambio de flotación libres.

### 1.1.2.- El tipo de cambio

En el mercado de divisas se intercambian unas monedas por otras, por lo que el precio es la relación de cambio entre ellas. Esta relación se denomina tipo de cambio nominal e indica la cantidad de divisa que el mercado ofrece por una unidad de otra.

La forma más utilizada por los operadores de divisas para expresar la relación de cambio entre dos divisas es la siguiente:

$$\text{Moneda A} / \text{Moneda B} = \text{Valor.} \quad (1.1)$$

La moneda de la izquierda se denomina base y la de la derecha contador. Esta anotación significa que 1 unidad de la moneda base es igual al valor en moneda contador. Al comprar, el tipo de cambio indica cuánto se debe pagar en las unidades de la moneda contador para comprar una unidad de la moneda base.

Las diferentes formas de expresar un tipo de cambio son las siguientes:

**T.C. nominal:** es el valor por el que una moneda se vende o compra respecto a otra. Suelen existir variaciones entre el tipo de cambio de compra y el de venta para dos monedas, que será el margen de beneficio que obtengan las casas de cambio de moneda.

**T.C. real bilateral:** se refiere al precio de los productos de la economía de un país respecto a otro, por lo que se incluye en el cálculo el deflactor del Producto Interior Bruto.

**T.C. real multilateral:** es una media ponderada de los tipos bilaterales, usando como factor de ponderación de cada uno la importancia del comercio bilateral con cada país.

El nombre de la divisa viene expresado a través de abreviaturas, que se corresponden con el código internacional ISO-4217, éste fue creado por la Organización Internacional para la Normalización (en inglés International Organization for Standardization ISO), para evitar las confusiones causadas por algunos nombres de divisas como dólar, que son utilizados en muchos países, pero tienen tipos de cambio distintos. Las dos primeras letras del código se corresponde con las dos letras del código del país de la moneda según el estándar ISO 3166-1 y la tercera es normalmente la inicial de la divisa en sí. El estándar ISO 4217 incluye también códigos para metales preciosos (oro, plata, paladio y platino) y otras definiciones utilizadas en el mundo financiero. Todos estos códigos comienzan con la letra "X". Los metales preciosos utilizan "X" y el símbolo químico del metal (por ejemplo la plata es XAG).

Por ejemplo, el tipo de cambio entre el euro y el dólar vendría expresado por la relación EUR/USD = 1.3212, donde las siglas siguen el estándar ISO-4217 [www-ISO-4217], y su valor representa el tipo de cambio nominal, en este caso por un euro se recibirían 1.3212 dólares.

Por otra parte, el tipo de cambio es doble: existe un tipo de cambio comprador y un tipo de cambio vendedor, este diferencial o spread es la ganancia que obtiene la entidad financiera por realizar el servicio de creador de mercado de divisas.

La variación mínima que puede ocurrir en el precio de cotización se denomina “PIP”. Este valor depende del número de decimales en la cotización del par. En el caso del EUR/USD es de 4 decimales, por tanto la variación sería de 0.0001 y ésto se correspondería con un “pip” para ese par. Sin embargo en el caso del USD/JPY la cotización sólo tiene dos decimales, por tanto la variación sería de 0.01. En la Tabla podemos observar los “pips” de las principales monedas.

	Bid (Precio de Venta)	Ask (Precio de Compra)	Spread (Diferencial)	Pipo (“PIP”)
EUR/USD	1.4229	1.4231	0.0002	2
USD/JPY	94.31	94.33	0.0200	2
EUR/JPY	134.1300	134.1700	0.0300	3

Tabla 1.- Tipo de cambio de las principales monedas Agosto 2009

El tipo de cambio puede ser directo o inverso, dependiendo del punto de vista de cada una de las partes. Por ejemplo, en Europa el tipo directo con el dólar USA sería: EUR/USD= 1,4229, mientras que el inverso es USD/EUR=0.7028. En el primer caso por un euro se obtendrían 1.4229 dólares, mientras que en el segundo, por un dólar se obtendrían 0.7028 euros.

Las monedas menos líquidas tienen un diferencial más grande, debido a que sus mercados son más reducidos y esto comporta mayor dificultad a la hora de comprarlas y venderlas. Por ejemplo, el diferencial correspondiente al par GBP/JPY es de 8 “pips”.

### 1.1.3.- Variaciones en el tipo de cambio.

Según [Lopez06] las variaciones en el tipo de cambio pueden ser explicadas por las siguientes teorías:

**Variación de las balanzas comerciales:** La balanza comercial entre dos países puede ser de superávit o déficit. Supongamos que un país A tiene superávit sobre otro B, Las empresas del país B han comprado más productos que han vendido. Por tanto, la demanda de la divisa del país A ha sido mayor que la del B. Esto hace que la divisa del país A se haya apreciado con respecto a la de B.

**La teoría de la paridad del poder adquisitivo (PPA):** Esta teoría se basa en que cestas de productos de consumo homogéneos de diversos países deben tener el mismo valor. Utilizando una nomenclatura en la que el numerador es la contraparte y el denominador es la base:

$$IPC_A = IPC_B * T_{A/B} \quad (1.2)$$

Es decir, el tipo de cambio depende de los niveles de precios relativos entre dos países

$$T_{\frac{A}{B}} = \frac{IPC_A}{IPC_B} \quad (1.3)$$

Si crece el nivel de precios en el país A, La moneda del país B se apreciará.

Dicha teoría funciona aceptablemente en el largo plazo pero no tanto en el medio y corto plazo, y sólo en países inflacionistas. Además, puede resultar difícil su aplicación, ya que los IPC puede que no sean homogéneos. La revista “*The economist*” realiza un estudio sobre la PPA comparando el precio de la hamburguesa BigMac de los restaurantes McDonalds en diferentes países con el precio que tiene en los Estados Unidos. La relación entre los precios debería ser el tipo de cambio teórico, el cual se compara con el tipo real, y calculando el tanto por ciento se genera un índice, denominado “*Índice BigMac*” [www-BicMac]. Éste nos indica si la moneda está sobrevaluada o devaluada. En la Figura 1 podemos ver la información para julio de 2013.

Es curioso observar cómo los países asiáticos tienen devaluada su moneda, según este índice, con respecto al dólar. Esta “devaluación competitiva” genera una competencia desleal. El presente estudio permite visualizar el comportamiento de la inflación en los distintos países. Si ésta crece, hace que los inversores saquen su capital hacia países donde ésta sea menor, y por tanto devalúa su moneda.

**Teoría de la paridad de los tipos de interés (PTI):** La paridad del tipo o tasa de interés es una teoría debida a Keynes, que describe la relación entre los tipos de cambio entre divisas y los

tipos de interés. Ésta demuestra que un inversor debe conseguir la misma rentabilidad invirtiendo en su país que invirtiendo en el extranjero. La paridad de tipo de interés representa un estado de equilibrio, en el que el beneficio esperado, expresado en divisa nacional, es el mismo para activos denominados en divisa nacional y activos denominados en divisa extranjera de riesgo y plazo similares, siempre que no se haga arbitraje. Es decir, que ambos mercados estén compensados. Ésto se debe a que el tipo de cambio en el mercado entre ambas divisas equilibra el retorno de ambas inversiones.

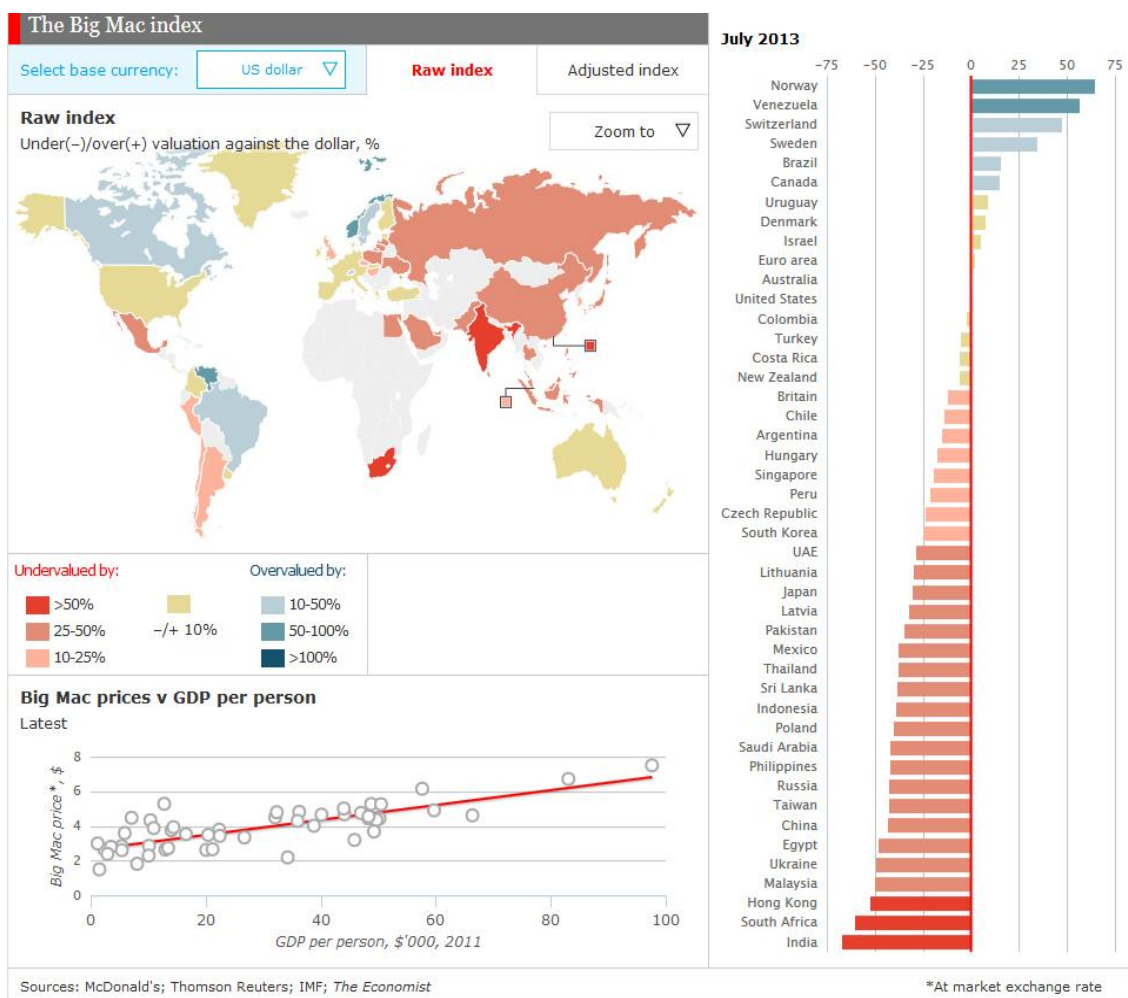


Figura 1.- Índice Bigmac (<http://www.economist.com/content/big-mac-index>)

Partimos de la base que el intercambio entre activos nacionales y extranjeros se puede realizar con facilidad, y que se pueden canjear activos con riesgo y plazos similares. Un inversor elegirá la inversión en activos con mayor beneficio esperado sin importar si es nacional o extranjero. Esta teoría genera dos supuestos: Paridad de tipo de interés descubierta y paridad de tipo de interés cubierta. Cuando se cumple la condición de no-arbitraje sin el uso de un forward (contrato a plazo) para protegerse de la exposición al riesgo cambiario, se dice que la paridad de tipo de interés es descubierta. Al contrario que en el caso anterior, cuando se cumple la condición de no-arbitraje junto con el uso de un forward para cubrirse (hedge) de la exposición al riesgo cambiario, se dice que la paridad de tipo de interés está cubierta.

### El efecto Fisher Internacional

Esta teoría, debida a Irving Fisher [Fisher30], describe la relación entre la diferencia de los tipos de interés nominal entre dos países y el tipo de cambio entre sus respectivas divisas. La relación entre el tipo de interés nominal  $i$ , el real  $r$  y la tasa de inflación  $f$  es:  $(1+i) = (1+r) * (1+f)$ . Un aumento en la tasa de inflación  $f$  implica aumentar el tipo de interés nominal, siempre que el tipo de interés real se mantenga constante.

La hipótesis de la que parte la teoría del efecto Fisher es que el tipo de interés real, tipos de interés nominal menos la inflación, es independiente de variables monetarias. Para que los tipos de interés reales entre diversos países se equiparen, el país con menor tipo de interés nominal debería tener también una menor tasa de inflación y, por tanto, el valor real de su divisa debería incrementarse con el tiempo. Este teorema parte de la premisa de que el capital fluye libremente a través de los distintos países.

Esta teoría se resume en una ecuación que relaciona la variación de los tipos de cambio con el diferencial de interés entre dos países, conjugando “la teoría de la paridad del poder adquisitivo” y “la teoría de los tipos de interés”. La ecuación es la siguiente:

$$T_{\frac{A}{B}} = \frac{i_A - i_B}{1 + i_B} \quad (1.4)$$

Supongamos que el tipo de interés en A es del 2.5% y el de B es del 3%. La variación del tipo de cambio será de -0.0046. Esto quiere decir que en el futuro la moneda de A se apreciará y la de B se devaluará. Esto hace que un inversor no pueda aprovecharse del tipo del arbitraje en los tipos de cambio.

### Explicación monetaria

Algunos economistas consideran que las tasas de crecimiento de la cantidad de dinero determinan el tipo de cambio. La teoría cuantitativa de Fisher establece la ecuación de la velocidad del dinero como:

$$M * V = P * Y \quad (1.5)$$

Donde:

M: Cantidad nominal de dinero.

V: Velocidad de circulación.

P: Nivel de precios.

Y: Renta real.

Despejando el nivel de precios establecemos que:

$$P = \frac{M * V}{Y} \quad (1.6)$$



Por otra parte, sabemos a través de la teoría de la paridad del poder adquisitivo que el nivel de precios nacionales es igual al nivel de precios extranjero por el tipo de cambio. Por tanto,

$$P_A = P_B * T_{\frac{A}{B}} \quad (1.7)$$

Despejando en la ecuación anterior, podemos ver cómo el tipo de cambio es directamente proporcional a la masa monetaria y a la velocidad del dinero, y de manera inversa al nivel de precios extranjero y de la renta real nacional.

$$T_{\frac{A}{B}} = \frac{M * V}{P_B * Y} \quad (1.8)$$

El tipo de cambio depende de las ofertas de dinero relativas, las velocidades relativas y las rentas relativas entre dos países. Si todo se mantiene constante y se aumenta la masa monetaria se devaluará el tipo de cambio.

#### 1.1.4.- Los mercados de capitales y deuda internacionales

Los mercados financieros internacionales son el ente donde confluyen oferentes y demandantes de productos financieros. Éstos se dividen en función del activo que se negocie. Así, podemos encontrar los mercados de divisas en los que se intercambian monedas de distintos países, los mercados internacionales de capitales, donde se negocian acciones, obligaciones y créditos, y los mercados internacionales de derivados, en los que se realiza la compraventa de opciones y “*swaps*”.

El mercado internacional de divisas establece el valor de cambio de las distintas monedas en las que se van a realizar los flujos monetarios internacionales. Entre sus funciones destaca la de servir de mecanismo para financiar el comercio y las inversiones internacionales. Éste realiza 75% del total de operaciones interbancarias internacionales.

Según el segmento en el que operen los mercados se pueden dividir en:

- Por el plazo de entrega:
- Mercado al contado (*spot*)
- Mercado a plazo (*forward*)
- Mercado de futuros
- Mercado de opciones

#### 1.1.5.- Política Monetaria.

La política monetaria o política financiera es una rama de la política económica que usa la cantidad de dinero como variable para controlar y mantener la estabilidad económica. La política monetaria comprende las decisiones de las autoridades monetarias referidas al mercado de divisas, que modifican la cantidad de éste o el tipo de interés. Cuando se aplica para aumentar la cantidad de dinero, se le denomina política monetaria expansiva, y cuando se aplica para reducirla, política monetaria restrictiva.

Los objetivos fundamentales de las políticas monetarias son los siguientes: Establecer un valor estable para el dinero, maximizar el crecimiento económico y el nivel de empleo y evitar desequilibrios en la balanza de pagos. En muchas ocasiones estos objetivos son contrapuestos y es necesario intervenir para lograr un balance adecuado.

En la actualidad, para mantener los precios estables los bancos centrales controlan la inflación. Por ejemplo, en el caso de una inflación elevada, éstos emiten títulos, reduciendo la oferta monetaria y aumentando los tipos de interés, esto genera una disminución del consumo, tanto particular como empresarial, disminuyendo la producción y aumentando el desempleo. Esta cadena de acontecimientos hace que disminuyan las fuerzas inflacionistas. Además, la subida del tipo de interés genera un aumento del tipo de cambio y reduce el nivel de las exportaciones netas con el exterior.

Dichas actuaciones influyen en el corto plazo, ya que no pueden influir en el crecimiento económico a largo plazo. Este problema se conoce como *“inconsistencia temporal”*. Básicamente consiste en que el efecto inicial que provoca el banco central en el mercado es absorbido por éste volviendo al equilibrio.

La gestión de las políticas monetarias se lleva a cabo a través del siguiente conjunto de instrumentos:

- **Política de descuento.** Ésta determina el tipo de interés y el plazo de devolución de los préstamos que concede el banco central a los bancos comerciales.
- **Variación del coeficiente de caja.** El coeficiente de caja también llamado encaje bancario o coeficiente legal de reservas, indica qué porcentaje de los depósitos bancarios ha de mantenerse en reservas líquidas, o sea, guardado sin poder usarlo para dejarlo prestado
- **Operaciones de mercado abierto.** Los bancos centrales pueden realizar operaciones en el mercado. Estas consisten fundamentalmente en la compra-venta de activos como pueden ser oro, divisas, títulos de deuda pública y en general valores con tipos de renta fija [Fernandez11].

Además de los instrumentos indicados anteriormente, las autoridades monetarias tienen una influencia muy grande en el mercado y cualquier opinión genera el denominado *“efecto anuncio”*, que hace que se altere el comportamiento del mercado.

La influencia de la política monetaria en el valor de una divisa es fundamental. Una variación por parte de un banco central en la cantidad de masa monetaria o en la fijación del tipo de interés determina el valor de una divisa y de sus cambios de tendencia en el medio y largo plazo. Los efectos del dinero sobre la actividad económica real han sido motivo de estudio y controversia entre las diversas escuelas de pensamiento económico (clásica, keynesiana, monetarista, marxista, nueva clásica, real business cycles o RBC, nueva keynesiana, poskeynesiana y austriaca).

#### 1.1.5.1.- Tipos de política monetaria

La política monetaria puede ser expansiva o restrictiva, dependiendo si queremos poner más o menos dinero en circulación.

##### **Política monetaria expansiva**

Consiste en aumentar la cantidad de dinero en circulación. Esto se puede realizar a través de los instrumentos vistos anteriormente, es decir, reduciendo los tipos de interés, reduciendo el coeficiente de caja o comprando deuda pública.

##### **Política monetaria restrictiva**

Consiste en reducir la cantidad de dinero en circulación. Para ello se aplican medidas contrarias a las anteriores, es decir, aumentando el tipo de interés, aumentando el coeficiente de caja y vendiendo deuda pública.




Figura 2.- Política monetaria restrictiva (Izquierda) y expansiva (derecha)  
[http://es.wikipedia.org/wiki/Pol%C3%ADtica\\_monetaria](http://es.wikipedia.org/wiki/Pol%C3%ADtica_monetaria)

## 1.2.- Predicción en mercados financieros

### 1.2.1.- Análisis cuantitativo

El análisis cuantitativo trata de buscar modelos matemáticos que nos llevan del simple análisis de los precios de los activos hacia modelos probabilísticos sobre su comportamiento. Cuando éstos sólo utilizan una única variable se denominan modelos univariantes. El análisis univariante de series temporales nace a partir del modelo clásico de regresión lineal [Walpole98]. Éste propone una metodología para construir modelos, que tiene su origen en un trabajo de Box y Jenkins [Box70] y que ha sido desarrollada y aplicada a distintos campos.

Los modelos univariantes clásicos están basados en los siguientes procesos:

1. Los procesos autorregresivos (AR).
2. Los procesos de medias móviles (MA).
3. Los procesos mixtos (ARMA).

La aproximación a los procesos estocásticos con modelos AR o MA está restringida, en términos generales, a aquellos procesos estocásticos que cumplan la restricción de estacionariedad. Pero la mayoría de las series económicas no se comportan de forma estacionaria, bien porque suelen ir cambiando de nivel en el tiempo o porque la varianza no es constante.

**No estacionariedad en varianza.** Cuando en una serie no se puede sostener el supuesto de que ha sido generada por un proceso con varianza constante en el tiempo, la solución es transformar la serie mediante algún método que estabilice la varianza.

**No estacionariedad en media.** Una de las características dominantes en las series económicas es su comportamiento tendencial. Éste puede ser creciente o decreciente, exponencial o aproximadamente lineal. La no estacionariedad en media se puede modelar de diferentes maneras. Por un lado, es posible modelar tendencias, cambios sistemáticos de nivel, mediante modelos globales en los que se especifica la tendencia como una función del tiempo. Estos modelos en los que la serie evoluciona de una forma perfectamente predecible, se denominan modelos de tendencia determinista. Por otro lado, también se puede modelar dentro de la clase de modelos ARMA ( $p, q$ ).

### **Modelos ARIMA ( $p, d, q$ )**

La modelización ARIMA implica un estudio de la componente no sistemática, de carácter aparentemente aleatorio, para tratar de identificar algún patrón de interés en su evolución que ayude a entender la progresión de la serie completa. Por ello, la aplicación de modelos ARIMA suele realizarse por descomposición, analizando en primer lugar la tendencia de la serie, pasando después a observar la estacionalidad y concentrándose después en la identificación del componente filtrado de tendencia y estacionalidad.

Los modelos SARIMA se definen como el producto de 2 modelos ARIMA, uno con los parámetros dependientes de la longitud de la estacionalidad y el otro dependiente de la serie temporal analizada.

### **Modelos ARCH**

Mientras que los modelos ARIMA se aplican sobre series homocedásticas, es decir, de varianza constante, los ARCH (Modelos Autorregresivos Condicionalmente Heterocedásticos) [Engle82] se caracterizan por tratar de modelizar la heterocedasticidad de la serie. Es decir, no se debe de alisar la serie como paso previo a la modelización de la misma, lo que no es por sí mismo una ventaja al obligar a elegir una de las múltiples posibilidades de modelización ofrecidos por los ARCH.

Los resultados del trabajo de Poon y Taylor [Poon91] indican que los modelos ARIMA y los ARCH no son excluyentes. Las series generadas por un GARCH, prevista por el modelo heterocedástico se ajustaba mejor, pero era más volátil en la cuantía de los errores.

Los GARCH (Modelos Generalizados Autorregresivos Condicionalmente heterocedásticos) [Bollerslev86], extienden el modelo ARCH para incluir retardos en la varianza condicional.

Además de los presentados, existen otros modelos generados a partir de la evolución de los anteriores buscando mejoras concretas. En [Peña05] se puede encontrar un amplio compendio.

## **1.2.2.- Análisis técnico**

El Análisis Técnico (AT) es la disciplina que estudia los indicadores técnicos y las figuras que se presentan en los gráficos de las series temporales de precios, normalmente de precios de cierre y los volúmenes de negociación del producto que se quiera analizar: divisas, acciones, opciones, futuros etc. Es posible realizar una distinción entre Análisis Chartista y Análisis Técnico propiamente dicho, aunque en la actualidad ambos se engloban bajo este último nombre. El análisis chartista se basa en el estudio de las figuras que forman los precios como indicación de la tendencia que pueden seguir en el futuro, mientras que el análisis técnico, en

cambio, efectúa operaciones estadísticas y matemáticas con los precios, para determinar esta tendencia. En cualquiera de los casos, el objetivo final es la toma de decisiones para la inversión. El análisis técnico está ampliamente extendido como método de predicción en los mercados financieros [Plummer89]. Además, su uso por parte de los distintos agentes ha sido estudiado por diversas entidades financieras y bancos centrales [Taylor92].

El análisis técnico se basa en tres premisas fundamentales [Neely97]:

1. El mercado tiene toda la información disponible y está reflejada en el precio. El mercado se mueve en virtud de la oferta y la demanda, sin importar las causas que lo sustentan.
2. Los precios siguen tendencias de duración relativa en el largo plazo.
3. Los precios siguen patrones de comportamiento. Es decir, el mercado tiene memoria y, por tanto, los precios no se comportan de manera aleatoria como sugiere la Hipótesis de los Mercados Eficientes (HME).

Los cambios en los precios se deben a las actitudes individuales de los inversores, y a una gran variedad de motivaciones, entre las que podemos encontrar las económicas, monetarias, políticas o psicológicas [Pring91].

El análisis técnico en contraposición al análisis fundamental proporciona una buena aproximación local al comportamiento de los precios y obtiene de forma intuitiva una aproximación más cercana a la estructura económica subyacente. El análisis fundamental estudia todo lo que está relacionado con la empresa, sus estados financieros, su producto, clientes, futuros beneficios o futuras caídas en las ventas. Este análisis requiere de un conocimiento muy exhaustivo del sector que se esté analizando, ya que pueden ser muy distintos.

En el siguiente capítulo se va a tratar la Hipótesis de los Mercados Eficientes (HME) y su evolución histórica. El cumplimiento de ésta, en su versión débil, comportaría que el uso del análisis técnico no conlleva la obtención de beneficio alguno [Gonzalez03], y por tanto es fundamental demostrar que en el mercado real aparecen anomalías e inconsistencias, que hacen que ésta no se cumpla. Posteriormente veremos una visión histórica del análisis técnico.

#### **1.2.2.1- La hipótesis de los mercados eficientes**

El origen de las Hipótesis del Camino Aleatorio (HCA) y de la Hipótesis de los Mercados Eficientes (HME) se iniciaron con el libro escrito por George R. Gibson publicado en 1889 [Gibson89], donde se describen los mercados de acciones de Londres, París y Nueva York. En su libro Gibson dice: *“Cuando las acciones se cotizan en un mercado abierto, el valor que adquieren puede ser visto como el juicio formado por las mejores mentes”*.

Con esta afirmación, Gibson inicia la idea que hay detrás de la HME, donde el valor de los activos refleja las acciones que los inversores realizan utilizando la información que tienen a su disposición.

Por otra parte, La HME tiene sus orígenes académicos en la tesis doctoral de Louis Bachelier [Bachelier00], el cuál utiliza la matemática del movimiento browniano o aleatorio para el estudio de los precios de los bonos del gobierno francés. En ella, deduce que la esperanza

matemática de las ganancias de un inversor son cero. Einstein en 1905 publica resultados similares, proponiendo la misma idea, que los precios de las acciones siguen un camino aleatorio [Einstein05]. Estos estudios encuentran validez empírica en muchos autores [Working34], [Kendall53], [Cowles60] y [Osborne59]. En un trabajo teórico posterior, Samuelson muestra que en un mercado eficiente, desde el punto de vista del proceso de la información, los precios tienen que ser impredecibles [Samuelson65], [Bebczuk10].

A finales de la década de los 60 el consenso académico sobre la impredecibilidad de los precios es grande, sin embargo no existe una teoría precisa de precios de activos financieros. Por ello, Fama, siguiendo las ideas de Samuelson, desarrolla en 1970 la hipótesis de los mercados eficientes donde expresa las condiciones de equilibrio del mercado en términos de tasas de retorno esperadas, valores que son calculados en torno al conjunto de información disponible, y presuponiendo que estas tasas de retorno sean un juego justo. Fama presenta varios modelos para los precios de los activos, entre los que destacan el de martingala y el de camino aleatorio [Fama70].

Según Fama, los precios deben incorporar toda la información disponible en un mercado eficiente, y propone que diferentes niveles de información disponible dan lugar a distintas formas de eficiencia. Fama distingue tres clases de eficiencia, de acuerdo al nivel de información disponible [Fama 70]:

**Forma débil:** Los precios actuales de los títulos reflejan totalmente toda la información contenida en los movimientos “pasados” del precio. Con esto, los precios fluctuarán más o menos aleatoriamente. No es posible hallar estrategias de inversión basadas en precios históricos de las acciones u otros datos financieros históricos para lograr rendimientos que superen a los del mercado, puesto que todos los participantes del mismo sabrán cómo interpretar las señales que las series históricas de precios pueden mostrar y actuarán en consecuencia. La forma débil de la hipótesis implica que el análisis técnico no es útil.

**Forma semi-fuerte:** Los precios actuales del mercado reflejan no sólo los movimientos pasados del precio, sino también toda la “*información pública disponible*”. Los precios de los activos se ajustan instantáneamente a toda información que se hace pública y no puede lograrse un rendimiento superior al del mercado utilizando ésta. La hipótesis semifuerte implica que las técnicas del análisis fundamental no serán capaces de lograr rendimientos superiores a los del mercado, ya que éstos ajustan sus precios rápidamente cuando se producen los eventos. En general, la literatura de eventos en finanzas apoya la forma semi-fuerte de la HME [Kothari05]. La única forma de lograr un rendimiento superior al promedio es a través de la utilización de la información privilegiada.

**Forma fuerte:** Los precios actuales del mercado reflejan toda la información relevante, incluso la privada. El precio de los activos la refleja y nadie puede obtener un rendimiento superior al del mercado. La información privilegiada parece negar la hipótesis fuerte.

Esto tiene importantes implicaciones predictivas pues, aunque cualquier técnica de predicción lineal sobre los cambios de precios futuros basada en los precios históricos será necesariamente inefectiva, no se niega la posibilidad de ganancias predictivas de momentos condicionales de órdenes superiores explotando algún tipo de relaciones no lineales entre las series temporales.

Desde el punto de vista de la predicción, la hipótesis de la martingala implica que la mejor predicción del precio de mañana es simplemente el precio de hoy. Tal propiedad se considera como una condición necesaria de mercado eficiente en su forma débil, que veremos posteriormente, pues expresa que la información contenida en los precios pasados está instantánea, plena y perpetuamente reflejada en los precios corrientes de los activos [Campbell97]. Otro aspecto de la hipótesis de la martingala es que los cambios de precios no solapados se encuentran incorrelacionados, lo que implica la ineffectividad de cualquier regla lineal de predicción de los cambios futuros de precios basados solamente en su propia historia.

Posteriormente Malkiel, llevado por las ideas de Fama, escribe su famoso libro *"A Random Walk Down Wall Street"* [Malkiel73], donde propone que los inversores deben invertir mejor en un índice diversificado que en unas acciones particulares. Este autor, en 1992, formaliza una definición de la HME diciendo [Malkiel92]:

*"Un mercado es completamente eficiente si refleja toda la información para determinar los precios de los activos financieros. Formalmente, se dice que un mercado es eficiente con respecto a un conjunto de información, si la revelación de información a todos los participantes no afecta a los precios de los títulos. Más aún, la eficiencia con respecto a un conjunto de información conlleva a que sea imposible obtener beneficios económicos en base al conjunto susodicho de información".*

Una definición de mercado eficiente la podemos encontrar en [Aragones94]: *"Un mercado es eficiente, cuando los precios de los bienes que se negocian en él, reflejan toda la información disponible e incorporan de forma completa e inmediata la nueva información, constituyendo los precios señales eficientes en la asignación de recursos".*

A mediados de los setenta la HME, en su versión semi-fuerte, fue una hipótesis ampliamente aceptada en la literatura económica. No obstante, la teoría de los mercados eficientes no concuerda con numerosos acontecimientos como los sucedidos en los mercados bursátiles en octubre de 1929, en octubre de 1987, en octubre de 1997, tiempos de crisis de las materias primas, inestabilidad internacional (guerras), burbujas, etc. Tampoco es capaz de explicar las tormentas monetarias que sacudieron los mercados cambiarios europeos entre 1992 y 1994; en general la HME no es capaz de explicar por qué los precios de las acciones presentan más volatilidad que lo que cabría esperar de la evolución de sus variables fundamentales [West88].

A partir de la década de los ochenta ya eran muchos los investigadores que tenían dudas sobre la eficiencia de los mercados, existiendo numerosas evidencias empíricas contrarias a la HME. Por ejemplo, Grossman y Stiglitz [Grossman80] indican que los precios de los activos no pueden incorporar toda la información disponible según la HME, salvo que el coste de su compra-venta y de la obtención de información sean cero. Jensen [Jensen78] propone una definición en la cual los precios reflejan toda la información, siempre que los beneficios marginales de actuar sobre ella no excedan a los costes marginales. Otros estudios han mostrado las inconsistencias con el modelo puro de paseo aleatorio o forma débil de la HME [Chiarella92]. Estos trabajos advirtieron anomalías relativas al exceso de rendimientos debidos a una variedad de factores tales como tamaño de la firma, sentimientos del mercado, días de la semana, etc.

De hecho, el propio Fama en 1991 vuelve a revisar la literatura sobre HME y encuentra numerosos estudios que demuestran que algunas variables macroeconómicas, financieras y de finanzas corporativas tienen poder para predecir los retornos de las acciones. También la hipótesis del camino aleatorio, históricamente relacionada con la HME, es puesta en duda por varios autores [Lo88], [LeRoy73], [Rubinstein76] y [Lucas78] entre otros. Estos autores demuestran que un proceso de martingala, como el propuesto por Fama [Fama70] para los precios de activos no es condición suficiente ni necesaria en un mercado financiero con inversores racionales. Si el precio de un activo es parcialmente predecible se debe a que un retorno justo se tiene que pagar por atraer a los inversores hacia ese activo, y así compensar a estos por el riesgo de comprarlo. Es así que Fama sugiere que las investigaciones se deben enfocar no tanto a hacer pruebas de hipótesis sobre las tres formas de eficiencia, sino en pruebas de hipótesis sobre la predicción de tasas de retorno, estudios de eventos y pruebas de hipótesis sobre información privada.

En [West88] se encuentra una recopilación de diversas investigaciones relativas al exceso de volatilidad de los precios de las cotizaciones. Este exceso de volatilidad apunta hacia la presencia de fuerzas dinámicas intrínsecas relacionadas con la especulación en los mercados. West cuestiona la idea de que los precios de los activos estén determinados, exclusivamente, por los valores fundamentales esperados racionalmente. En resumen, hoy en día la HME no constituye un paradigma real para operar en los volátiles mercados financieros.

Por otra parte, el profesor Lo de la Sloan School of Management del MIT, publicó un excelente trabajo donde se establecen las bases para un marco teórico del análisis técnico [Lo00].

#### 1.2.2.2- Visión histórica del análisis técnico.

El origen del análisis técnico podría asociarse con el trabajo de Alexander [Alexander61], que aplicó una regla de filtro en la que se compra un activo cuando su precio se incrementa un tanto por cien desde su último soporte y se vende cuando su precio cae un tanto por cien desde su última resistencia. Otros autores, [Fama66] presentaron un análisis empírico más detallado de dichas reglas, corregidas por dividendos y costes de transacción, llegando a la conclusión de que tales reglas no mejoran la simple estrategia de *"Buy and Hold"*.

Desde finales de los ochenta se ha puesto especial énfasis en contrastar la posibilidad de predecir los rendimientos bursátiles [Fama88] [Fama91] y [Lo88]. No obstante, es en la década de los 90 cuando el análisis técnico experimentó un mayor auge, un trabajo crucial en este sentido es el de [Brock92]. En dicho trabajo se contrasta la capacidad de obtener beneficios de las dos reglas técnicas más populares (medias móviles y ruptura del rango) en el índice Dow Jones. Los autores concluyen que los rendimientos obtenidos mediante estas estrategias no son consistentes con los cuatro modelos más utilizados en finanzas: el Paseo Aleatorio, AR (I), el GARCH-M y el GARCH exponencial. Es decir, que las diversas reglas usadas en el índice Dow Jones eran capaces, de generar beneficios frente a los modelos econométricos más empleados en finanzas. Igualmente otros trabajos [Bessembinder95], [Mills96] y [Fernández99] presentan evidencias similares para los mercados asiáticos, británico y español, respectivamente.

Las discrepancias entre los resultados obtenidos por los distintos autores en relación al poder predictivo del análisis técnico han conducido a una profunda reconsideración sobre el modo de elaborar las reglas técnicas. En este sentido, [Lo90] concluye que las especificaciones *"ad-hoc"*



de los parámetros que se emplean en las reglas técnicas, provocaba fisgoneo en los datos. Asimismo concluían que, de haber empleado técnicas de optimización para la elección de dichos parámetros, estas desviaciones se podían haber reducido e incluso, en algunos casos, eliminado. En este sentido, uno de los objetivos que pretende cumplir este trabajo es la generación de una metodología basada en Algoritmos Evolutivos (AEs) para la optimización de los parámetros de las reglas técnicas, permitiendo, además, incorporar nuevos elementos para el control del riesgo y de los costes de transacción asociados.

En los apartados anteriores se ha estudiado el análisis cuantitativo y el técnico como las principales técnicas para la predicción de precios. Las estrategias de inversión cuantitativas presentan una escalabilidad limitada [Zhao06], lo que dificulta la adopción de una estrategia cuantitativa de inversión a gran escala alternando mercados distintos.

En cuanto a la comparación de los rendimientos medios que ambas técnicas proporcionan, el análisis cuantitativo se comporta mejor en aquellos mercados con poco volumen de cotización, según aumenta éste, el análisis técnico es superior [Ahmed05], [Wermers07]. Consecuentemente, y dado que el objeto de estudio de este trabajo es el mercado de divisas, eur/usd, con un volumen de cotización diario enorme, parece lógico que el análisis seleccionado sea el análisis técnico.

### **1.2.3.- Computación evolutiva en economía**

Un modelo de conocimiento adaptativo o evolutivo debe tratar de responder la siguiente cuestión: ¿Qué proceso utilizan los agentes mediante el cual actualizan sus expectativas y toman sus decisiones en un determinado entorno? En este modelo es igual de importante la decisión que toma un individuo y lo que puede derivarse de la misma, como la evolución o el proceso de aprendizaje y de adaptación al medio que lo ha llevado a inclinarse por la decisión tomada y no por otra de las posibles alternativas. Por eso la relevancia de un modelo que explique no sólo la decisión tomada por un agente sino la evolución hasta llegar a ella. De ahí la conectividad entre el modelo biológico y el económico.

Según Tunzelman [Tunzelmann91], desde Malthus, en su ensayo sobre la población humana, se observa el uso de los principios generales del modelo evolutivo en la economía, y a partir de la obra de Nelson y Winter [Nelson82], proliferaron bastantes investigaciones en su misma línea [Smith94], [Taylor78], [Arifovic94] y [Arifovic00].

Los trabajos en éste área de investigación son múltiples: Predicción con series temporales [Koza92], [Iba93], e [Ivakhenko71], desarrollo de nuevos indicadores [Yan07], [Allen99], [Arifovic00], en procesos de Minería de Datos [Szpiro02], en la búsqueda de una estrategia que minimice el riesgo de operaciones diarias de compra-venta de acciones [Kaboudan02], [Bodas13], predicción de la volatilidad [Pereira02], [Keber02], teoría de juegos [Chen02]. En el trabajo de Clark y Juma se puede encontrar una revisión de las teorías evolutivas en el pensamiento económico. [Clark88].

Para la predicción de series temporales basadas en la aplicación de Programación Genética, se pueden seguir tres aproximaciones [Santini01]:

- 1.- Aproximaciones que usan Programación Genética u otro Algoritmo Evolutivo para optimizar una red neuronal, que intentan modelar una serie temporal concreta [Dorsey98], [Zhang97], [Zhang99], [Parisi06].
- 2.- Algoritmos basados en Programación Genética, que buscan crear una estructura (por ejemplo, árboles de decisión), que de forma indirecta represente el conocimiento asociado a una serie temporal [Oussaidène97].
- 3.- Algoritmos Genéticos que crean una expresión o un programa simple que calcula los valores futuros de una serie temporal basándose en los valores pasados o crean nuevos indicadores técnicos que emiten órdenes de compra y venta.

En [Lohpetch09], [Lohpetch10] y [Lohpetch11] se hace un exhaustivo repaso sobre el estado del arte en el empleo de computación evolutiva para la operativa bursátil.

Otras técnicas también han sido empleadas en la predicción de mercados financieros, como son: Las **redes neuronales** [Gatelly96], [Kutsurelis98], **lógica difusa** (*'fuzzy logic'*) [Andreu04], **híbridos** entre las redes neuronales y la lógica difusa [Li05] y **Modelos Ocultos de Markov** (*'Hidden Markov Models'* o HMM) [Hassan05].

Para finalizar, se deben citar algunos artículos donde se expone con detalle la técnica en la que se basa la presente investigación y resumen de resultados conseguidos: [Fernández07], [Fernández08], [Bodas09] y [Bodas12], [Soltero12].

### 1.3.- Introducción a los indicadores técnicos

Un indicador técnico es la representación gráfica de una serie de datos obtenidos mediante la aplicación de distintas fórmulas matemáticas sobre la serie de precios y/o volúmenes de un activo determinado. Estas series contienen uno de los cuatro movimientos de los precios en un periodo determinado, es decir, los correspondientes a la apertura, a los precios máximos y mínimos alcanzados, y al cierre. Cualquiera de estas cifras puede ser elegida para la obtención de los indicadores, aunque generalmente se utilice la de cierre. Algunos indicadores incluyen también los volúmenes de cada periodo. Los indicadores se dividen en dos grandes grupos, indicadores de valores e indicadores de mercado [Perez10]:

#### 1.- Indicadores de valores.

Son los que se obtienen a partir de los datos de los valores individuales a los que se aplican. Dentro de este grupo se encuentran cinco subgrupos de indicadores: tendencia, volatilidad, regresión, momento y volumen.

#### 2.- Indicadores de Mercado.

Se obtienen a partir de los datos recogidos de algún agrupamiento de valores, por ejemplo, todos los valores de un mercado, un índice, etc. Éstos no son aplicables a valores individuales.

En esta tesis se trabajará con los del primer grupo y más concretamente con un indicador de tendencia y otro de momento, que se explicará en las siguientes secciones. La razón de esta selección se basa en que los estudios estadísticos presentes en la literatura sitúan a las estrategias con estos dos indicadores como una de las más óptimas [Elder93].

### 1.3.1.- Indicadores de tendencia.

Una media móvil, tal y como su nombre indica, es una media sobre un conjunto de valores (precios, volúmenes...) que tiene la particularidad de que su cálculo se efectúa sobre un número concreto de datos ( $n$  días) que marcan el período. A medida que se incorpora un nuevo dato desaparece el primero, para mantener siempre este período de cálculo. Con una media se obtiene una suavización de los precios, lo que permite disminuir "el ruido" y tener una visión más clara de su dirección. Eso sí, a costa de retrasar la actuación del mercado. Una media móvil simple proporciona el mismo peso a todos los datos, mientras que una exponencial realiza una ponderación de los mismos. Las medias móviles se utilizan para visualizar la tendencia del mercado. En el siguiente apartado vamos a estudiar el indicador de tendencia utilizado en éste trabajo.

#### 1.3.1.1.- MACD

El MACD ('Moving Average Convergence Divergence'), fue desarrollado por Gerald Appel en 1970, y es un indicador que mediante el cruce de la línea del indicador (MACD) y de su media móvil (Sign) proporciona señales de compra o venta. El MACD se mueve alrededor de una línea central o línea cero, sin límites superior e inferior. En castellano, es traducido como convergencia-divergencia de medias móviles.

La formulación matemática está basada en la diferencia entre dos media móviles concretas, una larga y otra corta. Matemáticamente, y siguiendo los parámetros típicos, el MACD se suele calcular de la siguiente forma:

$$\text{MACD} = \text{MME}(\text{Cotiz})_{12} - \text{MME}(\text{Coti})_{26} \quad (1.9)$$

$$\text{Sign} = \text{MME}(\text{MACD})_9 \quad (1.10)$$

Siendo  $\text{MME}(\text{Cotiz})_i$  la media móvil exponencial de las cotizaciones de las últimas  $i$  sesiones (en nuestro caso 26 sesiones y 12 sesiones) y  $\text{MME}(\text{MACD})_9$  la media móvil exponencial de las últimas 9 sesiones del MACD. Los parámetros 26, 12 y 9 son los parámetros de entrada típicos a este indicador. Sin embargo, en este trabajo se propone seleccionar estos valores mediante AEs.

Las principales señales de operación se producen cuando la curva del MACD corta a su media móvil. Las señales de compra se generan cuando la línea del MACD corta en forma ascendente a la línea de su media móvil (Sign). Mientras la línea del MACD esté por encima de su media móvil la posición seguirá siendo compradora. Por el contrario se produce una señal de venta cuando la línea del MACD corta en sentido descendente a su media móvil. Cuando la línea del MACD esté por debajo de su media móvil la posición seguirá siendo vendedora.

El MACD es un indicador de tendencias que identifica el inicio o el agotamiento de una tendencia, por lo que en los movimientos laterales es mejor ignorar las señales de compra o venta y esperar que se confirmen. Éste también se puede emplear también como un indicador de divergencia. Cuando el precio de la acción está subiendo y el MACD desciende (divergencia negativa) o viceversa (divergencia positiva), se puede considerar una señal que predice el cambio de tendencia. No obstante, en el caso de esta tesis se ha dejado la evaluación de esta opción para investigaciones futuras.

### 1.3.2.- Indicadores de momento.

Este tipo de osciladores expresan la velocidad de variación de los precios, la cual se mide comparando el precio de hoy con el precio de  $n$  días antes, ya sea mediante su diferencia aritmética o mediante su división. El primer criterio no suele utilizarse porque no está normalizado y su interpretación puede variar con cada activo. El segundo es más empleado, ya que puede aplicársele diversos cambios que permiten reajustar su escala, mejorando sus prestaciones. Entre los indicadores más importantes de este tipo podemos encontrar los siguientes: Oscilador de momento, oscilador de tasa de variación de los precios, oscilador de fuerza relativa o RSI y oscilador estocástico. En este trabajo sólo utilizaremos este último, por que como indica Elder [Elder93] es el mejor para la operativa real. En el siguiente apartado se explica.

#### 1.3.2.1.- Estocástico

El Oscilador Estocástico (Stochastic Oscillator en inglés) fue desarrollado en los años cincuenta por George C. Lane. Es una variable estadística que está construida a través de la posición de una cotización con respecto a su máximo y a su mínimo, dentro de un período específico. Por tanto, esta variable se mueve dentro del intervalo cerrado entre cero y cien por ciento.

De acuerdo al propio autor, este indicador le da seguimiento a la velocidad o el momentum del precio. Como regla general, el momentum cambia de dirección antes de que lo haga el precio. De esta manera, las divergencias alcistas o bajistas en este indicador pueden emplearse para pronosticar posibles cambios de tendencia en el precio de un activo financiero en el mercado.

Las fórmulas generales para calcular los dos parámetros de este indicador son las siguientes:

- $\%K = (\text{Cierre actual} - \text{Mínimo más bajo}) / (\text{Máximo más alto} - \text{Mínimo más abajo}) \times 100$
- $\%D = \text{Media móvil simple de 3 periodos del \%K.}$

donde:

**-Mínimo más bajo:** El valor más bajo del conjunto de periodos analizado.

**-Máximo más alto:** El valor más alto del conjunto de periodos analizado.

**-%K** es multiplicado por 100 con el fin de mover el punto decimal dos lugares a la derecha.

La configuración por defecto para el oscilador estocástico es de 14 periodos, que pueden ser meses, semanas, días, horas o cualquier otro marco de tiempo intradiario. Un  $\%K$  calculado con base a 14 periodos emplea el cierre más reciente, el máximo más alto y el mínimo más bajo de los últimos 14 periodos. La línea del  $\%D$ , que es la media móvil simple de 3 periodos de  $\%K$ , se traza junto a este para que actúe como **línea de señal**. El oscilador estocástico mide el nivel del cierre con respecto al rango entre el máximo y el mínimo durante un periodo de tiempo determinado.

El oscilador estocástico genera valores por arriba de 50 cuando el cierre está en la mitad superior del rango de precios y abajo de 50 cuando el cierre se encuentra en la mitad inferior del rango. Valores menores de 20 en el oscilador indican condiciones de sobre venta que pueden anticipar un rebote y alza del precio. Por el contrario, movimientos por encima de 80 en el indicador señalan condiciones de sobre compra que pueden ser el preludio de una caída en el precio.

## 1.4.- Definiciones

### Tipo de cambio (Cotización)

Es el ratio de intercambio entre las divisas que componen un par. A la primera divisa, se la llama moneda base y el ratio de intercambio o precio de cotización ("quote"), es la cantidad de la segunda moneda que se necesita para comprar una unidad de moneda base. Por ejemplo, si la cotización actual del par EUR/USD es de 1.4000, significa que necesitamos 1.4000 dólares americanos para obtener un euro.

### "Pip"

Es la variación mínima que puede ocurrir en el precio de cotización. Este valor depende del número de decimales en la cotización del par. En el caso del EUR/USD es de 4 decimales, por tanto la variación sería de 0.0001 y esto se correspondería con un "pip" para ese par. Sin embargo en el caso del USD/JPY la cotización sólo tiene dos decimales por tanto la variación sería de 0.01, lo cual se correspondería con 1 "pip".

### Lote

Un lote estándar equivale a 100.000 unidades de moneda base, mini lote a 10.000 y micro lotes a 1.000. El beneficio por "pip" se calcula de la siguiente forma:

$$\text{Beneficio} = (\text{"PIP"}/\text{Cotización}) * \text{lote} \quad (1.11)$$

\*Al operar con un lote obtienes 10 dólares por "pip", si el USD no es la moneda base.

### Apalancamiento

El apalancamiento es una herramienta que permite comerciar grandes volúmenes con una cantidad de dinero disponible mucho menor. El apalancamiento más usual en Forex es 100:1 y 200:1. Por ejemplo, supongamos que tenemos 1.000 USD, y un apalancamiento de 100:1, entonces podríamos realizar una operación por valor de 100.000 USD.

### Margen

El margen es la cantidad de dinero necesario en la cuenta para garantizar las operaciones. Cada broker puede establecer requerimientos de margen diferentes. Se calcula según el tamaño de la operación y el apalancamiento. Por ejemplo, si operamos con 1 lote (100.000 USD) y tenemos un apalancamiento 100:1, nuestro margen requerido si la moneda base es USD de  $100.000/100=1.000$  USD. Esto significa que por cada lote operado necesitamos tener en la cuenta 1.000 USD. Por ejemplo, tomemos un operador con \$2.000 en su cuenta. Nuestro operador compra 1 lote de USD/JPY a un precio de 97.55, con el apalancamiento máximo de 100:1. Su margen utilizado es \$1000. Si el precio se mueve 100 "pips" a favor del operador (el índice de cambio se mueve hacia arriba un centavo a 98.55), el operador ganaría \$1.000 ( $\$10$  por "pip"  $\times$  100 "pips"). El operador ha duplicado efectivamente el tamaño de su cuenta, una ganancia del 50% sobre su cuenta de \$2.000, o una ganancia de 100% sobre su margen de \$1000. De manera opuesta, si la posición hubiese ido por lo menos 100 "pips" contra el operador, su posición se habría cerrado debido a una llamada de margen cuando la diferencia de su cuenta hubiese disminuido abajo de su requerimiento de margen de \$1000. El operador

tendría una pérdida de aproximadamente \$1000, o 50% de su cuenta inicial, y quedarían aproximadamente \$1000 en su cuenta.

### **Margen Libre**

Es aquel disponible para hacer operaciones. Por ejemplo, en una cuenta de 2.000 USD, se abre una operación de un lote, esto requiere un margen disponible de 1.000 USD. El margen libre disponible para el resto de operaciones es de 1000 USD. Una llamada al margen (Margin call) se produce si el margen requerido para cubrir las posiciones abiertas se agota, entonces el broker realizará una llamada de margen y cerrará todas las operaciones abiertas. De esta forma se evita que el saldo quede en negativo.

### **“Stop-loss”**

Éste consiste en fijar un nivel inferior a partir del cual la posición abierta queda automáticamente cerrada al alcanzarlo. De esta forma se limitan las pérdidas o se protegen las ganancias.

### **Take-Profit**

Es el valor, en número de “*pips*”, en el que se cierra la posición para la obtención de un beneficio. Al contrario del “*stop-loss*” supone un límite superior.

### **Trailing-Stop**

Éste se fundamenta en fijar un valor, normalmente en “*pips*”, a partir del cual el “*stop-loss*” se moverá de forma dinámica. Por ejemplo, iniciamos una orden de compra en el par EUR/USD a 1.4056 con un “*stop loss*” de 50 “*pips*” (1.4006, se cerrará la operación) y un Trailing Stop de 30 “*pips*”. Si el valor del alcanza los 1.4087, 31 “*pips*” de ganancia, entonces el valor del “*stop-loss*” seguirá siendo de 50 “*pips*”, pero su valor será de 1.4007. Por tanto, en el caso de bajada del mercado el stop estaría más arriba que al principio, maximizando nuestros beneficios.

### **Orden**

La entrada al mercado se realiza a partir de órdenes, una orden típica tiene los siguientes elementos: Par de divisas, Precio de apertura de la orden, “*stop-loss*”, “*Take-Profit*”, “*Trailing-Stop*”, Volumen de la orden en lotes.

### **Unidad Mínima Temporal**

La unidad mínima de tiempo con la que se va a operar en este trabajo es la operación (“*tick*”).

### 1.5.- Conclusiones y resumen

En este capítulo se han descrito los conceptos económicos necesarios para el posterior entendimiento de este trabajo. Y se ha dividido en tres grandes áreas: Economía y mercados de divisas, predicción en mercados financieros e introducción a los indicadores técnicos.

Al principio se ha visto la historia del mercado de divisas, desde sus inicios hasta su conformación final, haciendo especial hincapié en los siglos que van del XVIII al XXI. Este apartado es fundamental para entender el estado actual del mercado de divisas. También se han explicado los agentes que lo conforman, las principales operaciones que se realizan, los sistemas y tipos de cambio y sus principales variaciones. Además, se ha tratado brevemente conceptos relacionados con la política monetaria, sus corrientes de pensamiento y los instrumentos para llevarla a cabo. Todos estos elementos permiten centrar el mercado sobre el que se va a realizar esta investigación y la importancia que tiene a nivel global en el mundo.

A continuación, el trabajo se enfoca en las técnicas de predicción, más concretamente en las relacionadas con el análisis técnico, donde se conceptualiza y se ve una breve visión histórica. También se ha dedicado un pequeño apartado al análisis cuantitativo y sus modelos de predicción. Posteriormente se analiza la hipótesis de los mercados eficientes (HME), donde se explica pormenorizadamente y se ve su evolución en el tiempo. Básicamente lo que se trata de ver es que la eficiencia de los mercados no implica necesariamente que las diferencias de precios se comporten como caminatas aleatorias, ésto permite dotar de base teórica al análisis técnico y a éste trabajo. Posteriormente se incluye un breve resumen de la evolución de la computación evolutiva en la economía.

Finalmente, se han introducido los indicadores técnicos utilizados en ésta tesis, y se han incluido un conjunto de definiciones.

## 2. Algoritmos Evolutivos

---

2.1 Optimización y Heurísticas

2.2 Introducción a los algoritmos evolutivos.

2.3 Terminología de los algoritmos genéticos

2.4 Tipos de codificación.

2.5 Operadores genéticos.

2.6 Ajuste de los parámetros y criterios de detención.

2.7 La función de aptitud.

2.8 Algoritmos evolutivos para la optimización multiobjetivo.

2.9 Conclusiones

---



En este capítulo se recogen las definiciones fundamentales de optimización global y optimización multiobjetivo. Se describe qué se entiende por complejidad computacional y qué es la heurística. A continuación se explican brevemente los distintos métodos de optimización que se pueden utilizar, tanto los tradicionales como los más vanguardistas. Los métodos heurísticos, entre los que se integran los algoritmos evolutivos (EAs), han asumido gran protagonismo en la resolución de problemas de gran complejidad, especialmente aquéllos que son NP-completos.

A continuación se revisan los conceptos teóricos básicos sobre algoritmos evolutivos necesarios para desarrollar la aplicación de gestión de estrategias de “trading”. Inicialmente se trata de forma breve su historia y después se repasan los fundamentos y terminología básica. También se explica cómo se aplican éstos para resolver problemas multiobjetivo, introduciendo los conceptos de selección y ajuste, diversidad de la población y de elitismo. En el último capítulo se introducen los algoritmos de primera y segunda generación, explicando de forma más detallada los utilizados en éste trabajo.

## 2.1 Optimización y Heurística

En el mundo real raramente existen problemas en los que se trate de optimizar un único objetivo, más bien todo lo contrario, se trata de optimizar de manera simultánea múltiples objetivos diferentes y en muchas ocasiones contradictorios. En este tipo de problemas no existe una única solución, sino un conjunto de soluciones equiparables, que recibe el nombre de conjunto óptimo de Pareto. Sus fundamentos se definen en el siguiente punto.

La mayoría de los problemas que se plantean en el mundo real presentan múltiples objetivos contrapuestos. En cualquier campo actualmente se investigan problemas con estas características. Valgan como muestra unos pocos ejemplos representativos para comprobarlo. En la industria, se ha abordado el diseño en ingeniería [Andersson01] [Castejon07], la identificación de sistemas no lineales [Rodríguez99], [Reynozo11], el tratamiento de residuos [Mago09], [Rehnström00], o el control de procesos [Christofides01], [Silva02]. En los campos de la biología, la genética y la biología molecular [Morató99]. En medicina, como por ejemplo el control de la anestesia en operaciones quirúrgicas [Morari01], o el diagnóstico del cáncer de mama [Odusanya02]. En la mejora el tratamiento de datos y en la comprensión de los sistemas y procesos ecológicos [Leyva13] [Porter02], en el control del transporte de información a través de Internet [Steven02], y en procesos químicos [Masaharu03], [Beek02].

Por tanto, uno de los objetivos que persigue la industria es desarrollar algoritmos de optimización multiobjetivo capaces de enfrentarse a este tipo de problemas.

En este sentido, las técnicas heurísticas están alcanzando cada vez mayor auge. Una comparación de la eficiencia de las diferentes heurísticas aparece en [Pham00]. La justificación de porque estos algoritmos alcanzan la convergencia no está completamente desarrollada, pero se relaciona con la teoría de la optimización ordinal [Ho94], [Ho97], [Gong02]. De entre todas las técnicas heurísticas, los algoritmos evolutivos han experimentado un gran desarrollo, por su capacidad para encontrar soluciones a problemas muy complejos en un tiempo razonable. Un compendio bibliográfico sobre el uso de los algoritmos evolutivos en la resolución de problemas multiobjetivo se puede encontrar en [www-Coello].

El problema que se aborda en esta tesis es multiobjetivo, se caracteriza por la búsqueda de los parámetros óptimos para las soluciones de una estrategia determinada de “trading”. Entre los objetivos de la estrategia se encuentra maximizar el retorno de la inversión, el rendimiento y la diversificación y minimizar el riesgo. Para resolverlo se utilizaran las técnicas heurísticas que veremos en los próximos capítulos.

### 2.1.1.- Optimización global y multiobjetivo

Se van a presentar las definiciones fundamentales que son la base teórica de los problemas de optimización. Los conceptos y terminología empleados en el campo de la optimización multiobjetivo no están fijados de modo definitivo, y la terminología difiere en ocasiones ligeramente. Para una profundización en esta materia se puede recurrir a [Miettinen99].

La **optimización global** es el proceso que calcula el óptimo (mínimo o máximo) global en un espacio de búsqueda. [Bäck96] lo define como:

**Definición. 1: (mínimo global de un problema de optimización simple, SOP).**

**Dada una función:**

$$f(x): \Omega \subseteq \mathbb{R}^K / \mathbb{R}, \Omega \neq \emptyset, \text{ donde } x \in \Omega,$$

El valor  $f^* := f(x^*) > -\infty$  es llamado mínimo global si y sólo si:

$$\forall x \in \Omega: f(x^*) \leq f(x)$$

$x^*$  es la solución global mínima,  $f(x)$  es la función objetivo, y  $\Omega$  es el conjunto del espacio objetivo. Todo el razonamiento es análogo en el caso de considerar un óptimo global en vez de un mínimo.

Se puede concluir que el SOP tiene una solución única en el espacio objetivo.

Cuando la formulación matemática de un problema se plantea como la optimización de varios objetivos simultáneamente, el problema es llamado **optimización multiobjetivo**. Los objetivos a optimizar son habitualmente contradictorios, ya que si no serían redundantes. La solución de este problema no es un único punto del espacio de búsqueda como sucede en la optimización global (con un solo objetivo), sino que es un conjunto de puntos denominado conjunto óptimo de Pareto. Estas soluciones son óptimas en un amplio sentido, pues son aquellas que no son mejoradas por ninguna otra solución del espacio de búsqueda, cuando han sido considerados todos los objetivos.

Los problemas de optimización multiobjetivo (MOP), dependiendo de la aplicación, pueden ser definidos como criterios de optimización separados, o formulados como restricciones que debe cumplir el sistema a optimizar.

**Definición. 2: (problema de optimización multiobjetivo, MOP):** En general incluye un conjunto de parámetros (variables de decisión), un conjunto de  $k$  funciones objetivo, y un conjunto de  $m$  restricciones. Las funciones objetivo y las restricciones están dadas en función de las variables de decisión. El objetivo de optimización consiste en:

$$\text{maximizar} \quad \mathbf{y} = \mathbf{f}(\mathbf{x}) = (f_1(x), f_2(x), \dots, f_k(x))$$

$$\text{con las restricciones} \quad \mathbf{e}(\mathbf{x}) = (e_1(x), e_2(x), \dots, e_m(x)) \leq 0$$

$$\text{donde} \quad \begin{aligned} \mathbf{x} &= (x_1, x_2, \dots, x_n) \in \mathbf{X} \\ \mathbf{y} &= (y_1, y_2, \dots, y_n) \in \mathbf{Y} \end{aligned}$$

$\mathbf{x}$  es el vector de decisión,  $\mathbf{y}$  es el vector objetivo,  $\mathbf{X}$  es el espacio de decisión, e  $\mathbf{Y}$  es el espacio objetivo.


Las restricciones  $e(x) \leq 0$  determinan el conjunto de soluciones posibles.

**Definición. 3: (Conjunto factible (“feasible set”)).** El conjunto factible se define como el conjunto de vectores de decisión,  $x$  que satisface las restricciones  $e(x)$ :

$$X_f = \{x \in X / e(x) \leq 0\}$$

La imagen de  $X_f$ , esto es, la región factible en el espacio objetivo, está indicada como  $Y_f = f(X_f) = \bigcup_{x \in X_f} \{f(x)\}$ . Esto es, la región factible es un subconjunto del espacio objetivo.

Aquí se supone un problema de maximización, pero en general, para problemas de minimización o con combinaciones de maximizaciones y minimizaciones, las definiciones son similares.



**Fig. 3: Ejemplo de optimalidad en el espacio objetivo (izquierda) y una posible relación de las soluciones en el espacio objetivo (derecha).**

En un problema con un objetivo único el conjunto factible está completamente ordenado de acuerdo con la función objetivo,  $f$ : para dos soluciones  $a, b \in X_f$ , o  $f(a) \geq f(b)$  ó  $f(b) \geq f(a)$ . El objetivo es encontrar la solución (o soluciones) que proporcionan el valor máximo de  $f$  [Cohon85]. Sin embargo, la solución de un MOP no es única, ya que los distintos objetivos pueden estar en conflicto (la minimización de uno puede llevar a la maximización de otro). Cuando se tienen diferentes objetivos en cuenta, la situación cambia:  $X_f$ , en general, ya no está ordenado, sino sólo parcialmente ordenado [Pareto96]. Los MOP requieren una nueva definición de optimalidad. Esto puede observarse en la figura 3 a la izquierda. Si se trata de maximizar  $f_1$  y  $f_2$ , la solución representada por el punto  $B$  es mejor que la solución representada por el punto  $C$ , y  $C$  es una solución mejor que la representada por el punto  $D$ , pero no puede afirmarse que  $B$  sea mejor que  $E$  o a la inversa. Para expresar matemáticamente esta situación se extiende el uso de las relaciones matemáticas  $=, \geq, >$  a vectores objetivo, por analogía con el caso de único objetivo.

**Definición. 4: Para dos vectores objetivo cualquiera  $u$  y  $v$ ,**

$$u = v \text{ si y solo si } \forall i \in \{1, 2, \dots, k\} : u_i = v_i$$

$$u \geq v \text{ si y solo si } \forall i \in \{1, 2, \dots, k\} : u_i \geq v_i$$

$$u > v \text{ si y solo si } u \geq v \wedge u \neq v$$

Las relaciones  $\leq$  y  $<$  se definen de modo análogo.

Empleando esta notación,  $B > C$ ,  $C > D$ , y en consecuencia,  $B > D$ . Sin embargo, cuando se comparan  $B$  y  $E$ , no se puede afirmar que uno sea mejor que el otro, ya que  $B \not> E$  y  $E \not> B$ .

Por tanto, hay tres posibilidades cuando se comparan dos vectores objetivo  $\mathbf{a}$  y  $\mathbf{b}$  con la desigualdad  $\geq$  en un MOP (en contraste con las dos posibilidades que únicamente existen en un SOP):

$$f(\mathbf{a}) \geq f(\mathbf{b}), f(\mathbf{b}) \geq f(\mathbf{a}) \text{ y } f(\mathbf{a}) \not\geq f(\mathbf{b}) \wedge f(\mathbf{a}) \not\geq f(\mathbf{b}).$$

Las siguientes definiciones [Miettinen99], [Veldhuizen99], que tratan sobre la optimización de Pareto, se emplean para clasificar las diferentes situaciones.

**Definición. 5: (Dominancia Pareto)** Para dos vectores de decisión cualquiera,  $\mathbf{a}$  y  $\mathbf{b}$

$\mathbf{a} \succ \mathbf{b}$  ( $\mathbf{a}$  domina  $\mathbf{b}$ ) si y sólo si  $\forall i \in \{1, 2, \dots, k\} f(\mathbf{a}) \geq f(\mathbf{b})$  y además si como mínimo para uno de los índices  $f(\mathbf{a}) > f(\mathbf{b})$

$\mathbf{a} \succcurlyeq \mathbf{b}$  ( $\mathbf{a}$  domina débilmente  $\mathbf{b}$ ) si y sólo si  $\forall i \in \{1, 2, \dots, k\} f(\mathbf{a}) \geq f(\mathbf{b})$

$\mathbf{a} \sim \mathbf{b}$  ( $\mathbf{a}$  es indiferente respecto a  $\mathbf{b}$ ) si y sólo si  $f(\mathbf{a}) \not\geq f(\mathbf{b}) \wedge f(\mathbf{b}) \not\geq f(\mathbf{a})$

Las definiciones para un problema de minimización ( $\prec, \preccurlyeq, \sim$ ) son análogas.

En la figura 3 (derecha), el rectángulo azul claro envuelve la región del espacio objetivo que es dominada por el vector de decisión representado por  $B$ . El rectángulo azul oscuro contiene los vectores objetivo cuyos vectores de decisión dominan la solución asociada a  $B$ . Todas las soluciones que no se encuentran en ninguno de los dos rectángulos son indiferentes con la solución representada por el vector  $B$ .

El criterio de optimalidad puede introducirse basándose en el concepto de dominancia Pareto. Koopmans fue uno de los primeros en emplearlo en 1951 [Koopmans71]. Observando de nuevo la figura 3 (derecha),  $A$  es único entre  $B$ ,  $C$ ,  $D$  y  $E$ : su vector de decisión correspondiente,  $\mathbf{a}$ , no está dominado por ningún otro vector de decisión, lo que significa que  $\mathbf{a}$  es óptimo en el sentido de que no puede ser mejorado en ninguno de los objetivos sin que se produzca el empeoramiento en alguno de los objetivos restantes. Estas soluciones son denominadas Óptimo de Pareto, aunque también se emplea el término no-inferior [Cohon78].

**Definición. 6: (Optimalidad Pareto)** En un conjunto  $A \subseteq X_f$  Un vector de decisión

$\mathbf{x} \in X_f$  no está dominado si y sólo si  $\nexists \mathbf{a} \in A : \mathbf{a} \succ \mathbf{x}$ .

$\mathbf{x}$  es denominado Pareto óptimo si y sólo si  $\mathbf{x}$  no está dominado dentro de  $X_f$ .

En la figura 3 los puntos blancos representan las soluciones Pareto óptimas. Cada una es indiferente frente al resto, lo que origina la principal diferencia con los problemas monoobjetivo. No existe un único óptimo, sino un conjunto de óptimos equivalentes. Ninguno

puede ser identificado como mejor que el resto a no ser que se añada información sobre las preferencias, es decir, que se ordenen los objetivos mediante categorías (“ranking”).

El conjunto de soluciones óptimas de Pareto se denomina conjunto de óptimos de Pareto, y a los vectores objetivo correspondientes se les denomina superficie o **frente de Pareto**.

**Definición. 7: (Conjuntos y frentes no dominados)** Si se tiene  $A \subseteq X_f$ , la función  $p(A)$  proporciona el conjunto de vectores de decisión no dominados en  $A$ :

$$p(A) = \{a \in A \mid a \text{ no está dominado en } A\}$$

El conjunto  $p(A)$  es el conjunto no dominado de  $A$ , y el correspondiente conjunto de vectores objetivo  $f(p(A))$  es el frente no dominado de  $A$ . El conjunto  $X_p = p(X_f)$  es el conjunto de óptimos de Pareto y el conjunto  $Y_p = f(X_p)$  es el frente óptimo de Pareto.

El frente de Pareto incluye las soluciones globalmente óptimas. Sin embargo, de modo similar al SOP, pueden existir también óptimos locales, los cuales constituyen un conjunto no dominado dentro de una cierta vecindad. Esto corresponde a los conceptos de conjunto de óptimos de Pareto local y global [Deb98].

**Definición. 8:** Considerar un conjunto de vectores de decisión  $A \subseteq X_f$

El conjunto  $A$  se denomina conjunto de óptimos de Pareto local si y sólo si:

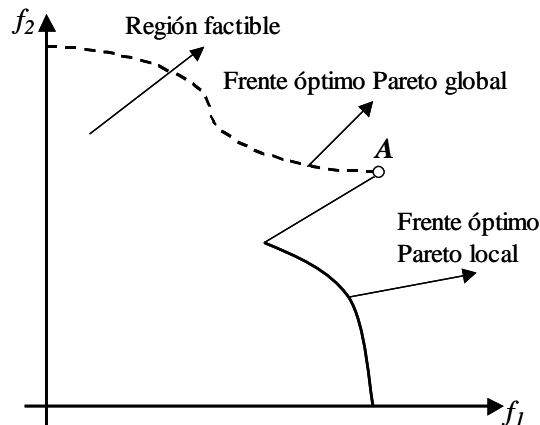
$$\forall a \in A : \nexists x \in X_f : x \succ a \wedge \|x - a\| < \varepsilon \wedge \|f(x) - f(a)\| < \delta$$

donde  $\| \cdot \|$  es una distancia métrica y  $\varepsilon > 0$ ,  $\delta > 0$ .

El conjunto  $A$  se denomina conjunto de óptimos de Pareto global si y sólo si:

$$\forall a \in A : \nexists x \in X_f : x \succ a$$

La diferencia entre óptimos locales y óptimos globales se visualiza en la figura 4.



**Fig. 4:** Conjunto de soluciones localmente óptimas y conjunto de soluciones globalmente óptimas en el espacio objetivo.

La línea discontinua constituye un frente de Pareto global, mientras que la línea sólida corresponde a un frente de Pareto local.

Los vectores de decisión asociados con el último son localmente no dominados aunque no son óptimos de Pareto, porque la solución asociada con el punto A domina a cualquiera de ellas. Finalmente, destacar que un conjunto de óptimos de Pareto global no contiene necesariamente todas las soluciones óptimas de Pareto y por otro lado, cada conjunto de óptimos de Pareto global es también un conjunto de óptimos de Pareto local [Miettinen99].

En esta tesis se abordan métodos de optimización multiobjetivo que son capaces de realizar un muestreo de espacios de búsqueda muy grandes y complejos y además de generar con exactitud o al menos aproximadamente el conjunto de óptimos de Pareto.

### 2.1.2.- Complejidad computacional y heurística.

#### 2.1.2.1.- Complejidad computacional

El campo de la complejidad computacional, desarrollado en paralelo a la Algoritmia, considera todos los posibles algoritmos, incluso los que aún no existen (porque no se hayan pensado) para resolver un determinado problema. Combinando ambas disciplinas, se intenta descubrir si para cada problema existe un algoritmo que sea capaz de resolverlo en un tiempo inferior a un límite impuesto.

Así, se pueden clasificar los problemas por su complejidad. El tiempo de cálculo permite distinguir diferentes tipos de problemas. Por ejemplo, están aquéllos que pueden resolverse en un tiempo de cálculo polinómico o de tipo P y los que no, a los que se denomina problemas **NP-completos**; pero no son los únicos. Los algoritmos de Monte Carlo dan lugar a la clase BPP (tiempo polinómico probabilístico con error acotado), los algoritmos de las Vegas originan la clase ZPP (tiempo polinómico probabilístico de error nulo), entre ambas clases está la RP (tiempo polinómico aleatorio), y hay además una nueva colección de clases de complejidad basadas en la idea de las computadoras cuánticas. A continuación se describen brevemente los dos primeros tipos, el P y el NP [Brassard97].

**Problemas de tipo P:** algunos problemas pueden resolverse mediante algoritmos de tiempo polinómico, es decir, algoritmos que requieren un esfuerzo computacional que es proporcional a un polinomio del tamaño del problema. Esto quiere decir que aunque el problema crezca, el tiempo de cálculo no será demasiado elevado y en la mayoría de los casos serán factibles.

**Problemas NP-completos** Hay otro tipo de problemas que se encuentran en la práctica, para los que no se conocen todavía algoritmos eficientes para hallar soluciones óptimas, y para los cuales, los algoritmos conocidos hasta el momento requieren un esfuerzo computacional que crece exponencialmente con el tamaño del problema. A estos problemas se les llama NP-completos, y para su resolución se suelen utilizar algoritmos de aproximación, que aunque no proporcionen el óptimo, sí aporten soluciones próximas al mismo. El problema del viajante es de este tipo, y también el problema de la mochila, la programación entera, la búsqueda del camino simple más largo de un grafo, etc. No se sabe si estos problemas son fáciles o difíciles de resolver, pero sí se conoce que todos ellos son de una complejidad parecida. La importancia

práctica de estos problemas ha hecho que cada uno haya sido estudiado por separado para hallar un método eficiente de solución.

### 2.1.2.2.- Heurística

De la necesidad de encontrar soluciones suficientemente buenas a problemas NP-completos en un tiempo de cálculo razonable surgieron las *técnicas heurísticas*. La optimización global de un problema multiobjetivo es un problema NP-completo [Bäck96]. La opción de tener una solución satisfactoria aunque no sea la óptima es muy rentable en muchos casos, y por ello comenzaron a surgir algoritmos denominados aproximados, que siempre pueden proporcionar soluciones de interés práctico: soluciones factibles (que satisfacen las restricciones del problema) que aunque no optimicen la función objetivo, se supone que al menos se acercan al valor óptimo en un tiempo de cálculo razonable. A estos algoritmos aproximados se les conoce como **métodos heurísticos**: pueden obtener una solución incluso globalmente óptima si hay fortuna, pero también puede dar lugar a una bastante alejada de la misma. La heurística puede ser probabilística o determinista.

La palabra '*heuriskein*', proviene del griego, y significa encontrar (Arquímedes empleó '*eureka*', que es un tiempo pasado de este verbo). Ésa es la finalidad de los métodos heurísticos. Desde comienzos de los años 60 se emplea este término para definir "procedimientos simples, a menudo basados en el sentido común, que se supone ofrecerán una buena solución, aunque no necesariamente la óptima, a problemas difíciles, de un modo fácil y rápido" [Zanakis89].

La explicación de por qué tienen éxito las heurísticas no está concluida, pero se está intentando relacionar con los conceptos de optimización ordinal [Ho94], [Ho97], [Gong02]. Esta teoría es capaz de predecir cuántas soluciones razonablemente buenas hay en el subconjunto de soluciones que la técnica heurística esté manejando en un momento determinado. Otra clave parece que es la introducción de conocimiento por mínimo que sea, para limitar el espacio de búsqueda.

Las dificultades que presentan los diferentes problemas que aparecen en el mundo real pueden describirse en función de las siguientes características: según el tipo de variables que tenga (discretas o continuas), según su dimensionalidad, multimodalidad, discontinuidades que presenta, epístasis (es decir, complejidad frente a los problemas que son separables linealmente), engaño, y tipo de restricciones que soporta (lineales, no lineales o sin restricciones). Para una descripción detallada de todas estas características, puede acudir a [Knowles02].

En este caso, se resuelve el problema para dos indicadores, unas determinadas condiciones de mercado y unas ventanas temporales como escala de la serie temporal de precios y 3 objetivos, maximización del retorno, maximización del número de operaciones (para maximizar la rentabilidad y la diversificación) y minimización del riesgo. De forma clara y demostrada la validez del procedimiento, la operativa empleada debe permitir la ampliación del problema a través, por ejemplo, de la incorporación de nuevos indicadores técnicos al cómputo.



### 2.1.2.3.- Ventajas de los algoritmos heurísticos

- Cuando no existe un método exacto de resolución, o éste requiere mucho tiempo de cálculo y gran cantidad de memoria. Ofrecer entonces una solución, aunque sólo sea aceptablemente buena es de interés, frente a la alternativa de no tener ninguna solución en absoluto.
- Cuando no se necesita la solución global óptima. Si los valores que adquiere la función objetivo son relativamente cercanos unos a otros, puede no merecer la pena el esfuerzo, con relación al coste, de hallar la solución global óptima que, por otra parte, no representará un beneficio importante respecto a otra subóptima.
- Cuando los datos son poco fiables o el modelo es una simplificación de la realidad. En este caso puede carecer de interés buscar una solución exacta, pues ese grado de exactitud no se está teniendo con los datos iniciales y por tanto puede no ser tan óptima para el sistema real.
- Cuando las limitaciones de tiempo y espacio (para almacenamiento de datos), etc., obliguen al empleo de métodos de rápida respuesta, aún a costa de la pérdida de precisión.
- Como paso intermedio en la aplicación de otro algoritmo. A veces son usadas soluciones heurísticas como punto de partida de algoritmos exactos de tipo iterativo, que al partir de una solución cercana al óptimo llevan mucho menos tiempo de cálculo.
- Permiten una mayor flexibilidad para el manejo de las características del problema respecto a las técnicas que buscan soluciones exactas. No suele resultar complejo diseñar algoritmos heurísticos que en lugar de considerar funciones lineales utilicen no linealidades.

### 2.1.2.4.- Desventajas de los algoritmos heurísticos

- Muchas heurísticas son válidas para un problema específico, no resultando útil para resolver cualquier otro. Por eso las técnicas de mayor interés son las que son fácilmente generalizables a un abanico amplio de problemas. Esa es una de las características de los algoritmos evolutivos.
- Por lo general no es posible conocer la calidad de la solución, es decir, cuán cerca está del óptimo global la solución que nos ofrecen.

Por estos motivos se desarrollan procedimientos evaluadores de la calidad de la heurística: usualmente test de funciones a optimizar, las cuales pueden tener características muy diferentes (óptimos locales, etc. según la dificultad deseada).

En esta tesis se abordan métodos de optimización multiobjetivo heurísticos que son capaces de realizar un muestreo de espacios de búsqueda muy grandes y complejos, además de generar el conjunto de óptimos de Pareto.

### 2.1.3.- Algoritmos de optimización

Existen muchos procedimientos de optimización distintos, cada uno con sus propias características, ventajas e inconvenientes. Veamos varias clasificaciones para tener una visión genérica del estado del arte de los algoritmos de optimización [Díaz96], [Herreros00].

- Según el tipo de búsqueda y el modo de construir sus soluciones:
  - Algoritmos de búsquedas explotadoras
  - Algoritmos de búsquedas exploradoras
  - Algoritmos de descomposición
  - Algoritmos constructivos
  - Algoritmos de reducción
  - Algoritmos de manipulación del modelo
  - Algoritmos de búsqueda por entornos
- Según el grado de aleatoriedad:
  - Algoritmos de búsqueda enumerativa
  - Algoritmos de búsqueda determinista
  - Algoritmos de búsqueda estocástica
- Según nuestro conocimiento de la complejidad o del dominio del problema
  - Algoritmos de búsquedas ciegas
  - Algoritmos de búsquedas dirigidas
- Según la naturaleza de las soluciones:
  - Algoritmos numéricos
  - Algoritmos combinatorios
  - Algoritmos de problemas de permutaciones
- Según el grado de penetración:
  - Algoritmos con grado de penetración alto
  - Algoritmos con grado de penetración bajo
- Según el número de candidatos:
  - Algoritmos de búsquedas simples
  - Algoritmos de búsquedas múltiples

### 2.1.4.- Métodos heurísticos de optimización.

Para resolver problemas de optimización multiobjetivo se conocen desde hace tiempo un amplio rango de técnicas heurísticas capaces de enfrentarse a su complejidad [Reeves93]: algoritmos de búsqueda aleatoria [Törn89], algoritmos de búsqueda local estocástica [Horst95], el recocido simulado o temple simulado (*'simulated annealing'*) [Törn89], la búsqueda tabú [Glover93], etc.

La estrategia más general para el diseño de algoritmos de aproximación es el método de **búsqueda estocástica pura**, consistente en evaluar  $N$  puntos del espacio de búsqueda de forma aleatoria y considerar que la solución es el mejor de los encontrados. La búsqueda estocástica orientada consiste en obtener puntos de forma aleatoria a partir de los puntos anteriormente encontrados [Timmer84] y [Rubinstein92].

La mejora iterativa, también llamada **búsqueda local**, es el método en el que se basan la mayoría de las heurísticas. Se basa en la técnica sencilla y natural del ensayo y error, pero a pesar de su sencillez ha proporcionado muy buenos resultados en muchos problemas difíciles

de optimización. La aplicación del método de mejora iterativa requiere la definición de un espacio de soluciones, una función de coste y de un conjunto de movimientos que pueden realizarse para modificar la solución actual y pasar a otra, cumpliendo siempre las restricciones del problema.

Una de las familias de métodos que podemos encontrar dentro de los procedimientos heurísticos es la de los llamados algoritmos evolutivos, que es con la que trabajaremos en esta tesis y que se explica en los siguientes apartados.

## 2.2. – Introducción a los algoritmos evolutivos

El término algoritmo evolutivo (AE), se emplea para englobar aquellos métodos de optimización heurística que basan su funcionamiento en la simulación de los procesos evolutivos de la naturaleza enunciados por Darwin [Bäck96]. El éxito de éstos respecto a los métodos clásicos se fundamenta en las siguientes cuatro razones:

- 1.- Los espacios de búsqueda sobre los que trabaja son muy grandes.
- 2.- En una única ejecución del algoritmo puede generar múltiples soluciones alternativas.
- 3.- Permite la incorporación de conocimiento de contorno del problema, lo que suele agilizar la búsqueda de soluciones.
- 4.- Evita los óptimos locales.

Los principios fundamentales en los que se apoyan son muy básicos, pero han demostrado ser un mecanismo de búsqueda general potente y robusta. Los autores Bäck, Hammel y Schwefel [Bäck97] argumentan:

“... la mayor ventaja de una búsqueda evolutiva es su mayor flexibilidad y adaptabilidad a cada problema, combinada con su robustez (aunque esto dependa del tipo de problema) y con sus características de búsqueda global.”

Como se indicaba inicialmente, los algoritmos evolutivos son capaces de obtener múltiples soluciones del conjunto óptimo de Pareto en una única ejecución del algoritmo, y a la vez explotar las similitudes de las soluciones mediante recombinación. Esto hace que los EAs sean especialmente apropiados para la optimización multiobjetivo.

### 2.2.1.- Breve historia de los EAs

El origen de los EAs se remonta a mediados del siglo XX, aproximadamente a los últimos años de la década de 1950 [Friedman56], [Fraser57], [Box57], pero no se proponen diferentes metodologías hasta la década de los 70. Las tres metodologías de investigación dominantes han sido la **programación evolutiva (EP)**, presentada por Fogel, Owens y Walsh [Fogel66], la **estrategia evolutiva (ES)** [Rechenberg73] y [Schwefel81], y los **algoritmos genéticos (GAs)**, introducidos por Holland en 1975 [Holland92]. Las diferencias entre las tres se están diluyendo para quedar englobadas en el término más general de **algoritmos evolutivos (EAs)**.

El desarrollo principal de Los EAs se produjo en los años 60. La idea era aplicar el concepto de la evolución natural a métodos de optimización para problemas de ingeniería. En 1964, un grupo de estudiantes de la Universidad Técnica de Berlín (Bienert, Rechenberg y Schwefel) se propusieron construir un robot de investigación que pudiera realizar una serie de experimentos. Inicialmente éstos no fueron muy bien, y fue entonces cuando Rechenberg introdujo el concepto de ES (*'Evolutionsstrategie'*) [Rechenberg73], que fue concebido como un método optimizador de parámetros con valores reales, y que ha servido como base de posteriores desarrollos basados en estrategias evolutivas, tal y como las conocemos hoy en día. Trabajos posteriores en esta área son los de Schwefel [Schwefel81].

Al mismo tiempo en Estados Unidos, Fogel, Owens y Walsh [Fogel66] desarrollaron la EP para hacer evolucionar una población de una máquina de estados finita, mediante una mutación aleatoria de sus diagramas de transición de estado y seleccionando el mejor. A esta técnica se la bautizó como Programación Evolutiva.

La tercera y más popular de las técnicas, los GAs, fue ideada por John Holland y sus colaboradores en la Universidad de Michigan. En contraste con la ES y la EP, el objetivo original de Holland no era diseñar un algoritmo para resolver un problema particular, sino estudiar el modo de incorporar el método de adaptación natural al campo de las computadoras.

El desarrollo de los EA no se ha detenido. La programación genética (GP), una rama de los GA es un ejemplo. Esta técnica fue creada por John Koza desde finales de los años 80 [Koza89], culminando el proceso en 1992 [Koza92] con la introducción de un método extendido de GA, de tal forma que estructuras simples pudieran evolucionar a estructuras más complejas, tales como programas completos de ordenador.

A finales de la década de los 80 se propuso la inclusión de operadores de búsqueda local en los EAs [Moscato89], lo que originó los algoritmos meméticos o híbridos. En los últimos años se ha profundizado en esta idea [Marchiorri99], [Sinha02]. También ha tenido un creciente interés las distintas posibilidades de paralelizar los EAs [Cantú99b].

En los últimos años ha surgido un gran interés, tanto teórico como práctico, en la utilización de los EAs para el tratamiento de problemas multiobjetivo, lo que ha originado los denominados EAs multiobjetivo (MOEAs). Los primeros estudios sobre estos aparecieron a mediados de la década de los 80 [Schaffer84], [Schaffer85], [Fourman85], y se propusieron diferentes implementaciones entre los años 1991-1994 [Kursawe91], [Hajela92], [Fonseca93], [Horn94], [Srinivas95].

Algunos autores indican que la búsqueda y la optimización multiobjetivo son un tipo de problemas que los EAs son capaces de afrontar mejor que otras estrategias heurísticas de búsqueda [Fonseca95a], [Valenzuela97]. Aunque esta afirmación debe ser calificada teniendo en cuenta los teoremas sobre optimización *"no free lunch"* [Wolpert97], hasta ahora no hay ninguna alternativa a la optimización multiobjetivo mediante EAs [Horn97]. Por este motivo han aparecido numerosísimas aplicaciones y es creciente el interés en los MOEAs.

Para una profundización de las diferentes técnicas que existen de MOEAs se puede acudir a [Fonseca95a], [Tamaki96], [Horn97], [Lis97], [Laumanns98], [Veldhuizen98b], [Deb99a],

[Coello99], [Coello00], [www-Coello]. Un estudio comparativo de diferentes MOEAs aparece en [Zitzler99], [Zitzler00].

Los MOEAs han sido aplicados sucesivamente y con éxito a diferentes problemas multiobjetivo [Ishibuchi96], [Cunha97], [Valenzuela97], [Fonseca98b], [Parks98]. En los últimos años algunos investigadores han profundizado en temas particulares de la búsqueda multiobjetivo evolutiva, como son la convergencia hacia el frente óptimo Pareto [Veldhuizen98a], [Rudolph98], los nichos [Obayashi98] y el elitismo [Parks98], [Obayashi98], [Everson02].

También se ha presentado un modelo unificado que intenta englobar todos los MOEAs [Laumanns00].

### 2.2.2.- Fundamentos de los EAs

Los diferentes tipos de EAs comparten una base conceptual común consistente en la simulación de la evolución de estructuras individuales por medio de procesos de selección y de reproducción. Estos procesos están en función del ajuste (*'fitness'*) que tienen las estructuras individuales a un determinado medio.

Más concretamente, los EAs conservan una población de estructuras que evolucionan de acuerdo con unas reglas de selección y con otros operadores, como por ejemplo la recombinación y la mutación. A estas estructuras individuales se les denomina individuos por analogía con la naturaleza, y cada uno de éstos representa una posible solución del problema. Se evalúa la calidad de cada individuo de la población respecto a la tareas de optimización, mediante una función de evaluación (*'fitness'*), obteniendo una medida de su ajuste al medio. Puesto que la relevancia está relacionada con las funciones objetivo y las restricciones, cada individuo debe ser decodificado antes de poder ser evaluado.

La selección entonces escoge aquellos individuos que tienen un valor del índice de ajuste muy alto, aprovechando de este modo la información que proporcionan, otorgándoles una probabilidad de reproducción muy elevada. Los operadores de recombinación (cruce) promueven el intercambio de información genética entre los individuos padre, produciendo descendientes, es decir, generan una explotación de la información. Por último, el operador mutación perturba la información genética de los individuos produciendo heurísticas generales para la exploración. El objetivo es enfocar la búsqueda hacia las regiones adecuadas del espacio de búsqueda, de modo que se incremente la calidad media de la población. El proceso se repite un número determinado de iteraciones o hasta que se cumple un determinado criterio de finalización. Aunque desde el punto de vista biológico son muy simples, estos algoritmos son lo bastante complejos para producir mecanismos de búsqueda robustos y potentes.

El algoritmo 2.1 describe un EA típico [Spears98]. Una población de  $P$  estructuras individuales se inicializa y a partir de ese momento evoluciona desde la generación  $t$  hasta la generación  $t+1$ , repitiendo los operadores de evaluación del ajuste, selección y recombinación. El tamaño de la población generalmente permanece constante en un EA, aunque ésta no es una condición obligatoria.

Cualquier EA por tanto debe tener cinco componentes mínimos para poder resolver un problema:

- Una representación del cromosoma.
- Un método para crear la población inicial.
- Un proceso de selección que requiere una función de evaluación.
- Operadores de recombinación y mutación.
- Los valores de los parámetros.

Un EA típicamente inicializa su población aleatoriamente, aunque se puede emplear conocimiento específico del problema para dirigir la búsqueda. La evaluación mide el ajuste de cada individuo de acuerdo con su valor en el medio. La evaluación del ajuste puede ser tan simple como el cálculo de una función matemática, o tan compleja como la ejecución de una simulación muy detallada. La selección se realiza a menudo en dos pasos: la selección de padres y la supervivencia. La selección de padres decide quiénes deben ser los padres y cuántos hijos deben tener. Los hijos son creados mediante el operador cruce, intercambiando información entre los padres, y mediante el operador mutación, que se encarga de modificar los hijos. Se evalúan los hijos, y finalmente se seleccionan aquéllos que deben sobrevivir en la población.

---

**Algoritmo. 2.1: Algoritmo evolutivo típico.**

---

Input:	$N$	(tamaño de la población)
	$T$	(número máximo de generaciones)
	$P_c$	(probabilidad de cruce)
	$P_m$	(probabilidad de mutación)
Output:	$A$	(conjunto de soluciones) (no dominadas)
Paso 1:	<b>Inicialización:</b> $t = 0$	
	a) Elegir la población inicial de acuerdo con una probabilidad de distribución	
Paso2:	<b>Evaluación:</b> se decodifica cada individuo y se calcula su valor de ajuste	
	<b>until</b> (criterio de terminación) <b>do</b>	
	<b>begin</b>	
Paso3:	<b>Selección:</b> de los padres	
Paso4:	<b>Recombinación:</b> se cruzan los individuos seleccionados con una probabilidad $P_c$ y generar hijos que se añaden a la población	
Paso5:	<b>Mutación:</b> Se alteran los individuos con una probabilidad $P_m$	
Paso6:	<b>Evaluación:</b> se decodifica cada individuo y se calcula su valor de ajuste	
Paso7:	<b>Selección supervivientes:</b> se pueden eliminar los peores individuos	

**End**

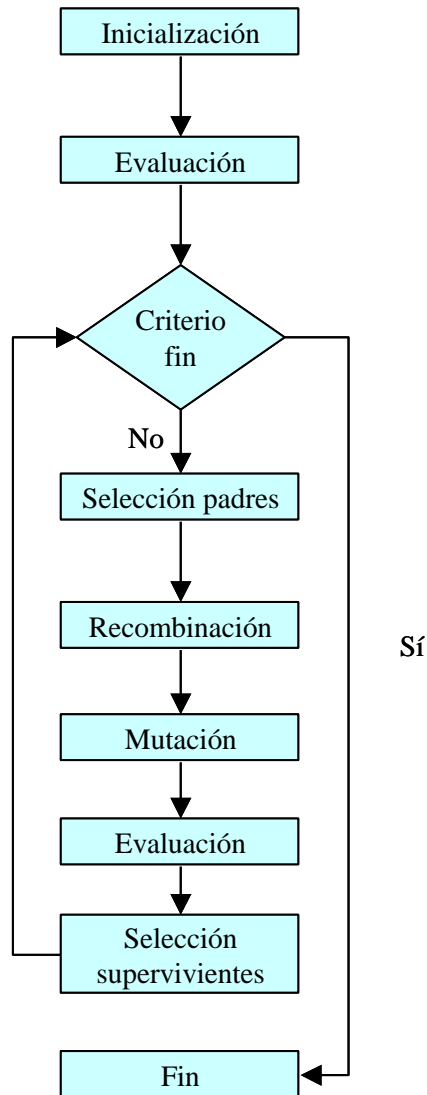


Figura 5.- Algoritmo evolutivo típico

A continuación se hace un breve repaso de los conceptos fundamentales de los EAs. Se revisan las ideas sobre la EP, ES y GP, y se analizan con más detalle los GAs, por ser éstos los que originan la mayoría de las técnicas evolutivas actuales.

### 2.2.2.1.- Programación evolutiva

La EP fue desarrollada por Fogel y colaboradores [Fogel62], [Fogel64], [Fogel66]. Ha empleado tradicionalmente representaciones que se ajustan al dominio del problema. Por ejemplo, en problemas de optimización del mundo real, los individuos de la población son vectores con valores reales. De modo similar, se usan listas ordenadas para problemas del tipo del viajante, o grafos para aplicaciones de máquinas de estado finitas. La EP se utiliza a menudo como método optimizador, pero surgió del deseo de generar máquinas inteligentes.

Después de la inicialización, todos los  $P$  individuos son seleccionados como padres, y después de aplicarles la mutación producen  $P$  hijos. Se evalúa a estos hijos, y se escogen  $P$

supervivientes de los  $2P$  individuos, usando un medio de selección probabilístico, como puede ser el método del torneo. El mejor individuo siempre sobrevive, asegurándose así que una vez que se ha alcanzado el óptimo éste ya no se pierda. Esta práctica se denomina **elitismo**. La forma de la mutación está basada en la representación empleada, y es a menudo adaptativa. Por ejemplo, cuando se trabaja con un vector de valores de números reales, cada variable dentro de un individuo puede tener una razón de mutación adaptativa con una distribución normal. La recombinación generalmente no se ajusta, ya que los métodos empleados en la mutación son lo suficientemente flexibles como para si se desea, producir modificaciones similares a la recombinación.

En esta tesis se ha incorporado a los algoritmos empleados la posibilidad de incorporar elitismo si así se requiere. Una comparativa de los resultados obtenidos con diferentes algoritmos que incluyen o no elitismo para resolver problemas de optimización multiobjetivo figura en [Zitzler99].

#### 2.2.2.2.- Estrategias evolutivas

Las ES fueron desarrolladas por Rechenberg [Rechenberg73], [Rechenberg94], usando selección, mutación y un tamaño de población igual a uno. Posteriormente Schwefel introdujo la recombinación con poblaciones mayores de un individuo, además de proporcionar comparaciones entre ES y otras técnicas de optimización tradicionales [Schwefel77], [Schwefel81]. Debido al interés inicial en los problemas de optimización hidrodinámica, las ES emplean típicamente representaciones de vectores de números reales.

Después de la inicialización y la evaluación, los individuos son seleccionados de modo uniformemente aleatorio para ser padres. En la ES típica, los padres producen hijos por medio de la recombinación, y después se modifican estos últimos mediante mutación. El número de hijos creados es mayor que el número de padres,  $P$ . La supervivencia es determinista y puede estar implementada con dos métodos diferentes. El primero es referenciado como *supervivencia*  $(P, \lambda)$ , donde  $P$  es el tamaño de la población y  $\lambda$  el número de hijos creados. Los  $P$  mejores hijos sobreviven, y reemplazan a todos los padres. Es por tanto un sistema no elitista. El segundo método es denominado *supervivencia*  $(P+\lambda)$ , en el cual son los  $P$  mejores individuos del conjunto de padres e hijos los que sobreviven, por lo que resulta un método que sí es elitista.

#### 2.3.2.3.- Programación Genética

Fue desarrollada por Michael Cramer y John Koza [Koza94], con la idea de generar de forma automática programas de ordenador en diferentes lenguajes y formas empleando operadores genéticos para tal fin.

#### 2.2.2.4.- Algoritmos Genéticos

Los Algoritmos Genéticos son un tipo de algoritmo de búsqueda heurística inspirados en la genética y la selección natural enunciada por el naturalista inglés Charles Darwin en el libro *"The Origin of Species by Means of Natural Selection Or the Preservation of Favoured Races in the Struggle for Life"* (El Origen de las Especies) [Darwin66]. El fundamento de esta teoría es que los individuos más aptos de una población son los que tienen más posibilidades de sobrevivir al adaptarse más fácilmente a los cambios que se producen en su entorno.



Los GAs fueron desarrollados por Holland [Holland92], y sus colaboradores (de entre los que destaca De Jong [83] de la Universidad de Michigan), a finales de los sesenta. Inicialmente empleaban una **representación** binaria de los individuos, pero actualmente y debido a la influencia de las ES [Rechenberg73], se manejan GAs que usan representaciones de vectores de números reales [Antonisse89] y [Wright91], o incluso grafos y expresiones LISP como sucede en la GP [Koza92]. De Jong demostró que los GAs son robustos frente a diferentes problemas de optimización con diferentes representaciones [DeJong91]. Además, los cromosomas pueden tener una longitud variable [Deb99b]. Una página Web de la armada de los Estados Unidos recoge muchos trabajos, enlaces e información actualizada sobre GAs [www-navy].

La computación evolutiva incluye otros algoritmos, no clasificados dentro del paradigma de los algoritmos evolutivos, como la inteligencia de enjambre (SI). Esta fue desarrollada por Gerardo Beni y Jing Wang en 1989 y se basa en el estudio del comportamiento colectivo de sistemas descentralizados y autoorganizados, naturales o artificiales. Normalmente están constituidos por una población de individuos que a partir de unas reglas simples interactúan entre sí y con el entorno, desarrollando una inteligencia colectiva. Este tipo de comportamiento se encuentra en la naturaleza: colonias de hormigas, bandadas de aves, crecimiento de bacterias, etc.

El conjunto de algoritmos basados en estos sistemas SI es muy amplio y algunos aún están en desarrollo. Entre los más importantes se pueden encontrar los siguientes: optimización mediante colonias de hormigas o abejas, sistemas inmunes artificiales, algoritmos de búsqueda gravitacional, algoritmos de optimización de partículas de enjambre (PSO), búsqueda de difusión estocástica etc.

Las tres metodologías dominantes de EAs que han sido presentadas, varían considerablemente con respecto a la representación empleada, a la selección y manejo de la población, y al uso de la recombinación y de la mutación. La EP hace mayor énfasis en la mutación, mientras que los GAs lo hace en la recombinación, y en las ES se emplean ambas. A pesar de varias décadas de trabajo con estos algoritmos, aún existen muchas incertidumbres sobre cuándo es conveniente o no el uso de uno u otro operador. Se han realizado varios estudios teóricos sobre el funcionamiento de estos operadores [Spears98].

## 2.3. – Terminología de los algoritmos genéticos.

### La población

Es el conjunto de individuos que representan al conjunto de soluciones evaluadas durante una generación. La **población inicial** generalmente se elige aleatoriamente, pero se puede emplear alguna heurística. La elección debe hacerse cuidadosamente, puesto que si la población inicial tiene unas pocas estructuras mejores que el resto, el algoritmo podría converger muy rápidamente hacia un óptimo local. Las técnicas usadas incluyen perturbaciones a la salida de un algoritmo avaricioso, inicializaciones con pesos aleatorios y perturbaciones de resultados obtenidos por un humano. También se pueden elegir elementos que hagan máxima la distancia de Hamming entre elementos, empleando por ejemplo las secuencias de Halton [Kocis97].

**Los individuos**

Un individuo representa una solución del problema planteado.

**Los genes**

Es una parte del cromosoma que codifica el valor de un parámetro, está acotado dentro de un cierto rango o dominio. Los valores que puede tomar son discretos. El espacio de búsqueda es directamente proporcional al número de parámetros. La estructura del gen depende de la función de codificación o mapeo empleada.

**Función de ajuste**

La medida de la adaptación de los individuos de la población al medio se realiza mediante la función de aptitud o fitness. Ésta determinará la probabilidad de reproducción posterior de los mismos.

**2.4.- Tipos de codificación.**

Desde la aparición de los Algoritmos genéticos se han utilizado diferentes formas de codificación: binaria, gray, real, hexadecimal, octal, etc.

Inicialmente se utilizó la codificación binaria, puesto que el teorema fundamental de los algoritmos genéticos: el teorema Fundamental del Esquema [Holland92, Goldberg89] (The fundamental Theorem of schemata), que trataremos de forma más detallada en este capítulo, establece que el alfabeto binario es el que ofrece el máximo número de schemata por bit de información de todos los sistemas de codificación. También esta codificación facilitaba el análisis teórico del algoritmo. Sin embargo, la mejora evolutiva es independiente de la codificación como demuestra Antonisse [Antonisse89] y como indicaba Goldberg en [Goldberg90].

De hecho, numerosos trabajos [Davis91, Deb94, Janikow91, Michalewicz96, Rajan 95, Voigt95, Walters 95, Wright91] han demostrado que la codificación real es computacionalmente más eficiente que la binaria. Posteriormente el trabajo de Eshelman y Schaffer [Eshelman93] logró la generalización del teorema del esquema planteado por Holland.

Los genes suelen representarse en forma de cadena definida por un vector  $s = \{s_1, s_2, \dots, s_j, \dots, s_n\}$ , donde  $s_j$  es el gen de la posición  $j$ . Los diferentes valores de  $j$  representan los alelos de ese gen. Representaciones en forma de matriz o árbol también son posibles.

Los individuos codificados deben cumplir con un conjunto de requisitos y principios que se recogen en los siguientes trabajos [Chen96, Rechenberg70, Rechenberg73].

**2.5.- Operadores genéticos.**

En los algoritmos genéticos se encuentran presentes los siguientes operadores: inicialización, reproducción (selección + recombinación) y mutación.

### 2.5.1.- Operador de inicialización

Se trata del operador que genera la población inicial o que reinicializa ésta para unas determinadas condiciones de contorno. La inicialización da lugar a un nuevo individuo dentro del dominio del problema. Los genes que conforman éste se ha generado de forma aleatoria. En ocasiones se pueden utilizar técnicas heurísticas adaptadas al problema ó soluciones conocidas para realizar la inicialización.

### 2.5.2.- Operadores de reproducción

Este operador es el encargado de la búsqueda de individuos nuevos y más adaptados al problema que se desea resolver. El proceso de búsqueda se focaliza en dos líneas contrapuestas, la exploración y la explotación. La exploración hace referencia a la búsqueda de soluciones más allá de las soluciones codificadas por los padres, mientras que la explotación se refiere a la búsqueda del óptimo guiada y acotada por éstas soluciones.

Una exploración intensiva hace el proceso de búsqueda sea lento al no generarse suficientes esquemas, mientras que lo contrario, una explotación excesiva puede provocar la convergencia prematura a un óptimo relativo. Por tanto, el proceso de configuración de estos operadores es fundamental para una búsqueda exitosa de nuevos individuos.

El ciclo reproductivo consta de tres pasos: selección de los padres, el cruce de los mismos para generar nuevos hijos (recombinación), y la mutación, que será la encargada de alterar el genoma de los hijos. En los siguientes apartados veremos un estudio más detallado de los mismos.

#### 2.5.2.1.- Operador de cruce

Es el principal **operador de recombinación**, aunque existen otros menos empleados, capaces de incorporar conocimiento específico del problema, como son: dominancia, diploide, duplicación, supresión, etc., o de evitar la destrucción de esquemas, como el operador inversión. Una descripción de todos ellos se puede encontrar en [Goldberg89].

El **operador cruce** simple se ejecuta en dos pasos: primero la población se empareja aleatoriamente. Después se selecciona una posición en las cadenas, de modo que se divide cada individuo por ese punto, y se intercambian sus alelos con su pareja. La combinación de los padres genera nuevos individuos que permiten la búsqueda en otros puntos el espacio de soluciones. La eficiencia de la búsqueda depende de la presión selectiva y también de la diversidad en la población. Normalmente en el proceso de cruce intervienen dos padres para generar dos hijos, aunque no siempre esto es así, ya que podrían intervenir más padres y generar un solo hijo [Eiben95].

El corte en la cadena cromosómica se puede producir en cualquier parte de la misma o en puntos determinados coincidentes con el fenotipo. En el primero de los casos se producen muchos individuos ilegales [Chen98].

Existen diferentes métodos para definir el punto o puntos de corte, así como la longitud de la cadena de material genético que se va a intercambiar. Esto da lugar a los siguientes operadores de cruce:

### Operadores de cruce determinísticos.

Son aquellos en los que los genomas de los hijos se obtienen intercambiando los genes de los padres, mediante determinadas reglas determinísticas. De este modo el gen  $i$  de un hijo se corresponde con el gen  $i$  del primer o segundo padre. Los más importantes son: Cruce por un punto [Holland68], [DeJong92], cruce por  $n$  puntos [DeJong75], cruce plano [Radcliffe91] y cruce uniforme [Syswerda89]. Estos operadores son especialmente adecuados para codificaciones binarias o enteras.

### Operadores de cruce aritméticos.

Estos operadores se utilizan para codificaciones con números reales o de punto flotante. Entre los más destacados encontramos los siguientes: cruce geométrico [Michalewicz96a], cruce por mezcla alfa (BLX- $\alpha$ ) [Eshelman93], cruce binario simulado (SBX- $\beta$ ) [Deb94, Deb96, Deb01]. En este trabajo se ha utilizado éste último y en el siguiente apartado se explica de forma más pormenorizada.

### Operadores de cruce multiparentales.

Son operadores basados en extraer las características estadísticas más relevantes de localización y dispersión de los individuos más aptos obtenidos en cada generación. Los más destacados son los siguientes: Cruce unimodal de distribución normal (UNDX-m) [Ono97, Ono03], Cruce parento-céntrico (PCX) Deb et al. [Deb90], cruce simplex (SPX) [Tsutsui02].

#### 2.5.2.1.1. Cruce binario simulado (SBX- $\beta$ )

Fue propuesto inicialmente por Deb [Deb94, Deb96, Deb01], con el objetivo de diseñar un operador para codificaciones con variables reales que simulara el comportamiento del operador de cruce por un punto binario y que respetara la construcción de esquemas a diferencia de los que ocurría con el operador BLX- $\alpha$ .

Inicialmente se define un factor  $\beta$  denominado factor de propagación, que mide la propagación de los genes de los hijos respecto a los de sus padres, y que se calcula para un gen  $i$ , como el cociente entre la distancia entre los genes de los hijos generados dividido por la distancia entre los genes de los padres.

Dados los padres  $X_{p1} = \{x_1, \dots, x_i, \dots, x_n\}$  y  $Y_{p2} = \{y_1, \dots, y_i, \dots, y_n\}$  y los hijos que se desean obtener  $X_{h1} = \{x_{h1}, \dots, x_{hi}, \dots, x_{hn}\}$  y  $Y_{h2} = \{y_{h1}, \dots, y_{hi}, \dots, y_{hn}\}$ , el factor de propagación  $\beta_i$  se calcula como:

$$\beta = \left| \frac{x_{p1} - y_{p2}}{x_{h1} - y_{h2}} \right| \quad (2.1)$$

Este factor clasifica los operadores de cruce en tres tipos:

1.- Si  $\beta < 1$  el operador de cruce es contractivo. Los genes de los hijos se encuentran localizados entre los de los padres. Este tipo de algoritmos se focalizan en la explotación.

2.- Si  $\beta > 1$  el operador de cruce es expansivo. Los genes de los padres se encuentran localizados entre los genes de los hijos. Esto implica que se explorarán zonas nuevas y por tanto, el algoritmo se centrará en la exploración.

3.- Si  $\beta = 1$  el operador de cruce es estacionario. Los genes de los hijos son los mismos que los de los padres.

Analizando la probabilidad de obtener un comportamiento contractivo, estacionario o expansivo se obtuvieron unas ecuaciones de ajustes polinómiales, para el cruce por un punto que proporcionan la distribución de probabilidad de obtener un tipo de cruce.

De este modo la distribución de probabilidad obtenida por Deb viene dada por la siguiente ecuación:

$$P(\beta) = \begin{cases} 0.5(\eta + 1)\beta^\eta & \beta \leq 1 \\ 0.5(\eta + 1)1/\beta^{\eta+2} & \beta > 1 \end{cases} \quad (2.2)$$

Donde  $\eta \in \mathbb{R}^+$  determina la probabilidad de generar nuevos individuos próximos o alejados de sus padres. Valores de  $\eta$  pequeños generan hijos muy alejados de sus padres mientras que valores de  $\eta$  grandes serán muy próximos a ellos. Para valores entre  $2 \leq \eta \leq 5$  el comportamiento del operador será similar al de un operador de cruce simple. Para  $\eta = 1$  se generaran cruces tanto expansivos como contractivos, por ello este valor se emplea de forma asidua.

La implementación se genera de la siguiente forma:

1.- Se genera un número aleatorio  $r \in \text{rnd}(0,1)$ .

2.- Se calcula  $\beta$  que tiene la misma probabilidad acumulada que  $r$  mediante la ecuación.

$$\beta = \begin{cases} 2r^{\frac{1}{\eta+1}} & r \leq 0.5 \\ \left[ \frac{1}{2(1-r)} \right]^{\frac{1}{\eta+1}} & r > 0.5 \end{cases} \quad (2.3)$$

Una vez determinado  $\beta$ , los hijos se calculan mediante la ecuación

$$\begin{aligned} X_{h1} &= 0.5 [(1+\beta) X_{p1} + (1-\beta) Y_{p2}] \\ X_{h2} &= 0.5 [(1-\beta) X_{p1} + (1+\beta) Y_{p2}] \end{aligned} \quad (2.4)$$

En la tabla podemos ver un ejemplo de cruce.

$X_{p1} = \{0, 1.0, 2.0, 3.0, 4.0, 5.0, 6\}$	$X_{h1} = \{0, 0.0, 2.0, 3.0, 4.0, 5.0, 7\}$
$Y_{p2} = \{0, 6.0, 5.0, 4.0, 3.0, 2.0, 1\}$	$X_{h2} = \{0, 7.0, 5.0, 4.0, 3.0, 2.0, 0\}$

Tabla 2.- Cruce binario simulado  $r=0.4$ ,  $\eta = 1(\beta = 1.27)$ .

### 2.5.2.2.- Operador de mutación

La mutación consiste en modificar ciertos genes de forma aleatoria atendiendo a una probabilidad establecida con anterioridad. En el caso de una codificación binaria será la inversión de un gen, que será el gen mutado, y que se corresponderá con un bit. Para la codificación numérica se sustituye un número por otro o se intercambia un número por otro que está en otra posición del cromosoma. En el caso de codificación por valor directo puede realizarse modificando el valor en unos decimales. Por último, en una codificación en árbol, la mutación podría radicar en el cambio de operador, de un número o incluso en la mutación de una rama entera.

Históricamente, en los GA se ha considerado la mutación un operador secundario, aunque esta situación ha cambiado totalmente y el interés en la mutación ha crecido en la década de los 90 debido a la influencia de la investigación en ES y EP. Schaffer y Eshelman demostraron experimentalmente que la mutación es un operador de búsqueda muy potente por sí solo [Schaffer89]. Un estudio comparativo de los operadores cruce y mutación aparece en Spears [Spears98].

Las mutaciones suelen ser en promedio beneficiosas, pues contribuyen a la diversidad genética de la especie. Además previene a las soluciones de la población a verse limitadas por un óptimo local. La mutación depende de la codificación y de la reproducción. Si se abusa de la mutación podemos caer en el uso del algoritmo genético como una simple búsqueda aleatoria. Por lo tanto antes de aumentar las mutaciones, conviene estudiar otras soluciones que aporten diversidad a la población como podría ser el aumento del tamaño de la población o garantizar la aleatoriedad de la población inicial.

Técnicamente es un operador unario porque actúa sobre un solo individuo, a diferencia de los operadores reproductivos. La probabilidad de mutación, de cada gen de un individuo, recomendada suele ser  $p_m \in [0.001, 0.01]$ , aunque algunos autores como Schaffer [Schaffer89] o Hesser y Männer [Hesser91] proponen otras expresiones.

La forma en la que se seleccionan los genes que se mutaran es la siguiente: Para todos los genes se producirá un número aleatorio entre  $r \in [0,1]$ , si  $r < p_m$  entonces se producirá la mutación de ese gen. Si cada gen es mutado con una probabilidad  $p_m$ , la probabilidad de que un individuo sea mutado vendrá dada por la ecuación

$$P_{mi} = 1 - (1 - p_m)^{n_g} \quad (2.5)$$

Los operadores más empleados habitualmente para codificaciones enteras o reales son los siguientes: mutación aleatoria uniforme [Michalewicz96], Mutación aleatoria no uniforme [Luke09], mutación de convolución gaussiana [Sanchez12], exponencial [Fogarty89] y mutación polinomial [Deb01b]. Veamos con más detalle ésta última que es la utilizada en este trabajo.

### 2.5.2.2.1.- Operador de mutación polinomial

El operador de mutación polinomial (PM) está basado en una función de distribución de probabilidad. Éste realiza una pequeña perturbación en los hijos  $o$ , para obtener la descendencia mutada  $O$ . El tamaño máximo de la mutación es igual a la diferencia entre los límites inferior y superior.

$$O_i = o_i + \beta (u_i - l_i), \beta \in [-1, 1] \quad (2.6)$$

Donde el parámetro  $\beta$  es calculado desde la distribución de probabilidad

$$P(\beta) = 0.5 (\eta_m + 1)(1 - |\beta|)^{\eta_m} \quad \beta \in [-1, 1] \quad (2.7)$$

Siendo  $\beta$ :

$$\beta = \begin{cases} (2u)^{\frac{1}{\eta_m+1}} - 1 & \text{si } u < 0.5 \\ 1 - (2 - 2u)^{\frac{1}{\eta_m+1}} & \text{En el resto de los casos.} \end{cases} \quad (2.8)$$

El número aleatorio  $u$  se encuentra en el intervalo  $[0,1]$ . Éste está representado en el algoritmo 2.2 en la línea 2, y representa el área bajo el pdf. Éste es utilizado para calcular  $\beta$ . En la Figura se muestra un ejemplo del operador PM y su pdf para diferentes valores de  $\eta_m$ .

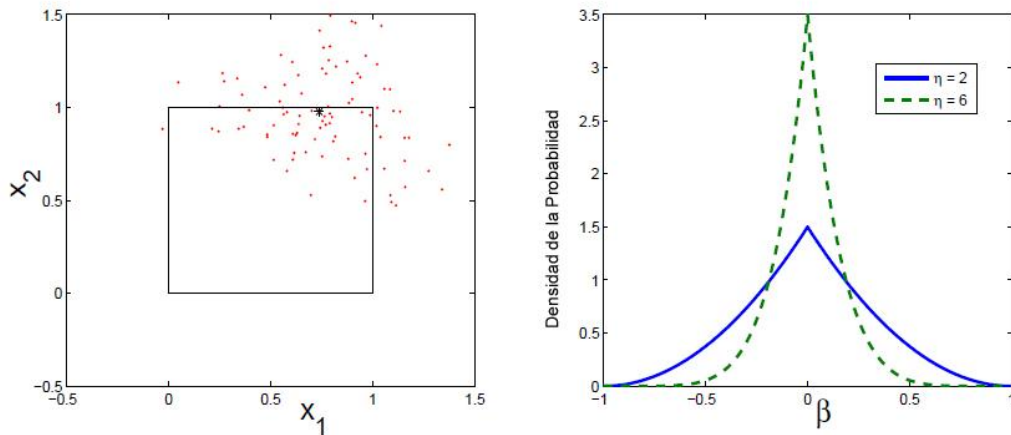


Figura 6.- Region factible  $Q=[0,1]^2$ . Algoritmo 3.1 genera 100 mutaciones de una descendencia. En alguno casos el individuo mutado queda fuera de la zona factible (izquierda). El fdp utiliza la mutación polinomial para valores de  $\eta=2$  y 6.

---

#### Algoritmo. 2.2: $O = PM(o)$

---

- 1: **for**  $i = 1, \dots, n$  **do**
- 2: Escoger un número aleatorio  $u \in [0, 1]$
- 3: Calcula el valor de  $\beta$  usando la ecuación (2.20)
- 4: ejecuta la mutación utilizando la ecuación (2.19)

---

5: end for

---

Cada vez que obtenemos un hijo es posible que este quede fuera del dominio de factibilidad. Para solucionar este problema se añade un parámetro extra denominado  $\alpha$ , el cual no está ajustado a priori. Este nos da una relación entre la frontera más cercana y el tamaño del dominio como sigue:

$$\alpha_i = \frac{\min(o_i - l_i, u_i - o_i)}{u_i - l_i} \quad (2.9)$$

PM aplica la idea de modificar el dominio del pdf con el fin de adaptarse a él, para un dominio acotado. Esto último aumenta la probabilidad de que la descendencia sea mutada en valores muy próximos. Si el descendiente está demasiado cerca de los límites, las mutaciones empieza a ser pequeñas perturbaciones y el resto de la región factible es ignorado.

### 2.5.2.3.- Operador de selección

El tercer operador fundamental en todo GA es el **operador selección**, el cual escoge los individuos que se van a reproducir. El conjunto de individuos seleccionados una vez aplicados los operadores de cruce y mutación engendrarán una nueva generación. Hay muchos tipos de selección. Los más conocidos son el método aleatorio puro, el de la ruleta (*'Roulette Wheel'*) [DeJong75], la selección por muestreo universal estocástico [DeJong75, Baker87, Grefenstette89], la selección por muestreo determinístico, la selección por muestreo estocástico del resto con y sin remplazo, selección por grupos [Thierens94], selección por rango, también denominado el método de las categorías (*'ranking'*) propuesto por Baker [Baker85], la selección de Boltzmann, la selección por torneo (*'Tournament'*) [Wetzel83] que se analiza matemáticamente en [Blickle95], y el de truncamiento (*'Truncation'*) [Mühlenbein93], [Bäck93]. En el siguiente apartado se explica con más detalle el utilizado en este trabajo.

#### 2.5.2.3.1.- Selección por torneo

Propuesta por Wetzel [Wetzel83], estudiada por Brindle [Brindle81], en su tesis y popularizada por Deb y Golberg [Deb89b, Goldberg91] es de las más efectivas y sencillas de implementar. El método consiste en seleccionar dos o más individuos de la población de modo que compitan entre sí para ser uno de los padres de la nueva generación. El vencedor será el individuo con mayor aptitud, repitiendo este proceso hasta elegir todos los padres.

El algoritmo 3.2 muestra esta implementación. Este algoritmo tiene la ventaja de no requerir la ordenación de la población en función de su aptitud, con la correspondiente mejora computacional. La función de aptitud no se utilizará para la selección del individuo, aunque sí para elegir el campeón. Esto asegura la diversidad en la población, y el mantenimiento de la presión selectiva cuyo valor esperado será:

$$\phi = 2^{n_{tor}-1} \quad (2.10)$$



Debido a sus características [Bäck95, Blickle96] es uno de los operadores de selección más eficientes y suele conducir a la obtención de óptimos absolutos [Whitley89].

---

**Algoritmo 2.3: Pseudocódigo del operador de selección por torneo**


---

```

Inicializar:  $P = \{\emptyset\}$ 
for  $i=1$  to  $n$  do
    for  $j=1$  to  $n_{\text{tor}}$  do
         $r_j = \lfloor n * \text{rnd}(0,1) \rfloor$  // Selección aleatoria de  $n_{\text{tor}}$  individuos
    end for
     $s = 1$ 
    for  $j=1$  to  $n_{\text{tor}}$  do
        for  $k = j+1$  to  $n_{\text{tor}}$  do
            if  $f_{r_j} < f_{r_k}$  then
                 $s=k$  // Determinación del individuo más apto.
            end if
        end for
    end for
     $P_i = P_{r_s}$ 
end for
return  $P$ 

```

---

Existe una variante del operador propuesta por Michalewicz [Michalewicz96] basado en la selección de Boltzmann, para el torneo binario, donde los dos individuos  $i$  y  $j$  compiten entre sí y donde la probabilidad de que gane el individuo  $j$  viene determinada por la fórmula:

$$P_{w_j} = \frac{1}{1 + e^{\frac{f_i - f_j}{T}}} \quad (3.10)$$

La probabilidad de selección de un individuo está ponderada según la probabilidad  $P_w$  determinada por la ecuación (3.10). Cuando las aptitudes de ambos individuos se aproximan, la probabilidad de ser el ganador se iguala. Otra característica es que cuando el tiempo transcurrido es grande, la probabilidad de selección tiende a igualarse aunque las aptitudes de los individuos sean muy diferentes. Esto último permite evitar el estancamiento de la población al permitir a individuos alejados de la zona de búsqueda entrar en el proceso de selección.

La [Tabla 3](#) muestra un resumen de la complejidad computacional de los diferentes operadores de selección [Goldberg91a]. De la observación de esta puede deducirse que los operadores menos adecuados son los de selección por ruleta y ranking.

Tipo de operador de selección	Tiempo o complejidad
Ruleta	$O(n^2)$
Muestreo universal estocástico	$O(n)$
Muestreo estocástico del resto	$O(n)$
Muestreo determinístico	$O(n)$
Selección por grupos	$O(n)$
Ranking	$O(n \ln n)$
Torneo	$O(n)$

Tabla 3.- Coste computacional de los diferentes operadores de selección

#### 2.5.2.4.- Operador de remplazo

Existen dos clases fundamentales de algoritmos genéticos dependiendo de la estrategia de remplazo empleada: Los algoritmos genéticos simples (SGA), también denominados con remplazo generacional (GGA), y los algoritmos genéticos con brecha generacional (SSGA). La diferencia entre ambos es que en la primera todos los padres son reemplazados por los hijos, mientras que en la segunda algunos padres sobreviven, la denominada brecha generacional [DeJong75], la cual puede tener un tamaño variable. En los primeros se emplean operadores elitistas para evitar la pérdida de los mejores individuos.

Los operadores de remplazo SSGA más utilizados son los siguientes: remplazo de los menos aptos [DeJong92], remplazo aleatorio [Davis91], torneo a muerte [Smith07, Smith98], remplazo del individuo más viejo, selección conservativa, remplazo de los progenitores, elitismo. En nuestro caso utilizaremos varios de estos operadores, pero principalmente elitismo.

### 2.6.- Ajuste de los parámetros y criterios de detención.

Los parámetros son un factor crucial a la hora de medir el desempeño del algoritmo evolutivo implementado. Existen dos tipos de ajuste principalmente: ajuste offline y ajuste online. El primero de ellos se basa en un ajuste por experiencia en problemas similares [Grefenstette86, Goldberg89, Woon03]. Finalmente los trabajos de Hart y Belew [Hart 91], y de Wolpert y Macready [Wolpert97], generaron un conjunto de teoremas que indican el motivo por el cual un algoritmo de búsqueda guiada debe necesariamente incorporar información sobre el problema a resolver para resultar efectivo.

Los algoritmos de búsqueda guiada son aquellos que parten de una función de distribución uniforme en el espacio de búsqueda y que la modifica en función de los resultados obtenidos en el muestreo anterior. En este tipo de algoritmos se incluyen todos los EAs, la búsqueda tabú y el SA.

Estos teoremas demuestran que dos algoritmos de búsqueda guiada, **A** y **B** tienen de media las mismas características en la resolución de todos los problemas de optimización posibles. Esto

implica que un algoritmo de búsqueda guiada necesita información adicional sobre el problema a resolver, y que las buenas cualidades que tenga en la resolución de un determinado tipo de problemas se convierten en características negativas cuando el algoritmo se enfrenta a otro tipo de problemas para el cual no fue diseñado. Por lo tanto, la comparación global de los EAs no tiene sentido, sino que deben evaluarse para cada problema concreto.

Por otra parte el ajuste online intenta que sea el propio algoritmo el que ajuste sus parámetros. Las técnicas actuales son de dos tipos: **Retroalimentación heurística** [Rechenberg73], y **autoadaptación** [Davis89].

En el primero se analizan distintas medidas como son la convergencia y la diversidad de los individuos de la población. A partir de aquí, algunos autores [Aine08, Baker85, Srinivas94] plantean diferentes reglas para la tasa de mutación, el punto o tipo de cruce etc., todo ellos en función de una serie de parámetros determinísticos. Otros autores plantean un control basado en redes neuronales o lógica difusa [Herrera96, Im08, Song, Voigt95].

En cuanto a la autoadaptación existen dos variantes principales: **coevolución** [Tuson96, Bäck96], donde se incluyen los parámetros del algoritmo dentro de su propia codificación. **micro-Algoritmo Genético** [Bäck94, Lee95, Mercer78, Shahookar90], los cuales utilizan a su vez otros algoritmos genéticos para la optimización y reajuste de sus parámetros.

Una vez que se alcanza la convergencia el algoritmo se detiene, los criterios de detención más habituales son:

1. Número máximo de generaciones o tiempo transcurrido máximo.
2. Valor de la aptitud constante durante t generaciones.
3. Estancamiento durante t generaciones.

## 2.7.- La función de aptitud o función objetivo

Es la representación del problema que se va a resolver y nos indica la bondad de las soluciones obtenidas. Es decir, nos mide la adaptación de los individuos al medio. El proceso de optimización parte de un problema general que incluye un conjunto de n variables de decisión, un conjunto de l funciones objetivo y un conjunto de m restricciones. Las funciones objetivo y las restricciones son funciones de las variables. El objetivo de la optimización es:

$$\text{Maximizar } y = f(x) = (f_1(x), f_2(x), \dots, f_l(x)), \text{ sujeto a } r(x) = (r_1(x), r_2(x), \dots, r_m(x)) \leq 0$$

$$\text{Donde } x = (x_1, x_2, \dots, x_n) \in X \text{ e } y = (y_1, y_2, \dots, y_n) \in Y$$

El vector de decisión es x y el objetivo y. X denota el espacio de decisiones, e Y el espacio objetivo. Las restricciones  $r(x) \leq 0$  determinan el conjunto de soluciones factibles.

Cuando una restricción satisface la condición  $r(x) = 0$  actúa limitando el espacio de soluciones factibles.

La gestión de las **restricciones** se lleva a cabo por distintas técnicas, entre las más importantes se encuentran las siguientes:

1. Funciones de **penalización** [Courant43, Carroll61, Fiacco66]: estática[Homaifar94], dinámica[Joines94], adaptativa [Bean92, Ben97, Lemonge04, coevolutiva [Coello99a], algoritmo genético agregado[LeRiche95], pena de muerte, fuzzy[Wu03]
2. Algoritmos de **reparación** [LeRiche95, Liepins90, Mühlenbein92, Orvosh93, Orvosh94, Tate95, Xiao96, Xiao97].
3. Métodos **híbridos**: Multiplicadores de lagrange [Adeli94], optimización restringida por evolución aleatoria [Belur97].

### 2.7.1.- Convergencia del los EAS.

Se ha demostrado que la convergencia hacia un óptimo global de un EA tiene probabilidad uno. Tanto para problemas con un único objetivo [Bäck96], como para problemas multiobjetivo [Rudolph98] y [Veldhuizen99]. Este resultado sólo es teórico puesto que se asegura el óptimo con un tiempo tendente a infinito.

No existe actualmente una teoría exacta sobre cómo se produce la convergencia de los EAs. Goldberg, con la hipótesis de los bloques constructivos ('building blocks') [Goldberg89], explica las combinaciones buenas de parámetros que provoca el operador selección, y la posible destrucción de las mismas debida a los operadores cruce y mutación, pero no incluye la probabilidad de creación de buenas estructuras que introducen estos dos últimos operadores. No es capaz de explicar el ruido colateral que supone que individuos con una parte de parámetros buenos y con valores de la función objetivo altos (próximos al óptimo), impidan la optimización de todos los parámetros. Los teoremas de 'No Free Lunch' [Wolpert97] demuestran que un EA debe incorporar conocimiento del problema que desea resolver para resultar eficaz, lo que hace que la comparación en términos absolutos entre la bondad de dos EAs diferentes no tenga sentido a no ser para un problema concreto.

Existen varias teorías que intentan explicar la convergencia de los EAs, en particular de los GAs, y el porqué de sus ventajas frente a otras heurísticas, pero la cuestión permanece abierta.

## 2.8.- Algoritmos evolutivos para la optimización multiobjetivo

Hay varios conceptos clave en torno a la búsqueda multiobjetivo que hay que conocer para entender cómo se puede construir un EA multiobjetivo (MOEA): los procesos de evaluación y de selección, la diversidad de la población y el elitismo.

Los MOEAs tienen la posibilidad de encontrar varias soluciones óptimas de Pareto en una única ejecución, debido al paralelismo implícito que poseen los EAs. Sin embargo la complejidad de la mayoría de los problemas hace que se deba orientar a los MOEAs hacia tres objetivos:

1. Minimizar la distancia del frente de Pareto obtenido respecto al frente óptimo de Pareto.
2. Es deseable una distribución adecuada de soluciones (uniforme en la mayoría de los casos).
3. Maximizar la extensión del frente no dominado, de modo que para cada objetivo un amplio rango de valores esté cubierto por soluciones no dominadas.

Para cumplir estos objetivos hay que resolver dos problemas:

1. Guiar la búsqueda hacia el frente óptimo de Pareto mediante los procesos de evaluación y de selección.
2. Mantener la diversidad en la población para evitar una convergencia prematura y lograr así un conjunto no dominado bien distribuido y amplio.

### 2.8.1.- Procesos de evaluación y selección

A diferencia de la optimización de un único objetivo en donde las funciones objetivo y de evaluación son a menudo idénticas, en la optimización multiobjetivo las funciones de evaluación y selección deben permitir que existan diferentes objetivos. En general se puede distinguir entre las técnicas que consideran los objetivos por separado, aproximaciones basadas en las técnicas agregadoras clásicas y aquéllos métodos que emplean directamente el concepto de dominancia de Pareto:

**Selección mediante intercambio de los objetivos:** en vez de combinar todos los objetivos en un único valor escalar de ajuste, esta técnica escoge entre los diferentes objetivos durante la fase de selección. Cada vez es un objetivo diferente el que decide qué individuo se selecciona para la reproducción. Es decir, los procesos de evaluación y de selección o se integran en uno sólo o se ejecutan alternativamente. Es posible que cada objetivo seleccione el mismo número de individuos para la siguiente generación [Schaffer85], o implementar un esquema de selección en el que los individuos se comparan teniendo en cuenta un orden específico (o aleatorio) de los objetivos [Fourman85], o asignar una probabilidad a cada objetivo que determina cuál de ellos será el criterio de ordenamiento en la siguiente selección. [Kursawe91]. Todas estas aproximaciones pueden sufrir desviaciones hacia soluciones extremas y no converger hacia el frente óptimo de Pareto [Horn97].

**Selección agrupadora con variación de parámetros:** está basada en las técnicas tradicionales revisadas en el capítulo 1. Todos los objetivos se agrupan en una sola función objetivo parametrizada. Se hace variar estos parámetros durante una ejecución del algoritmo. Algunos investigadores han empleado el método de los pesos [Hajela92], [Isibushi96], [Murata97]. Ya que cada individuo es evaluado por una combinación diferente de pesos, a cada individuo lo evalúa una función objetivo diferente. Por tanto, la optimización se hace en diferentes direcciones simultáneamente. Pero este método puede dirigirse hacia regiones convexas del frente óptimo de Pareto [Veldhuizen99].

**Selección basada en Pareto:** la idea de calcular el ajuste de un individuo en función de la dominancia Pareto fue propuesta por Goldberg [Goldberg89], el cual presentó un procedimiento de 'ranking' iterativo [Deb99b]. En primer lugar, a todos los individuos no dominados se les asigna un rango 1, y se les saca temporalmente de la población. Entonces, a los siguientes individuos no dominados se les asigna rango 2, y así sucesivamente. Por último, el rango de un individuo determina su valor de ajuste. Hay que tener en cuenta que aquí el ajuste está relacionado con toda la población, mientras que en el resto de las técnicas el ajuste de cada individuo se calcula independientemente del resto. Esta idea ha sido desarrollada de diferentes modos [Fonseca93], [Horn94], [Srinivas95]. Teóricamente, este tipo de MOEA es capaz de encontrar cualquier solución óptima de Pareto, aunque hay que tener en cuenta que la alta dimensión del espacio de búsqueda puede dificultar la convergencia [Fonseca95a]. Estas técnicas son las más empleadas [Veldhuizen98b], y por todo ello se escogió el algoritmo de

Fonseca y Fleming para abordar los problemas de optimización resueltos en esta tesis. Este algoritmo ha sido mejorado y modificado para hacerlo más flexible y eficaz, como se explica más adelante.

### 2.8.2.- Diversidad de la población

Mantener la diversidad de la población es fundamental para que un MOEA tenga una eficacia alta, puesto que debe encontrar un conjunto de soluciones diferentes que pertenezcan al óptimo de Pareto. Un EA simple tiende a converger a una única solución, con lo cual a menudo pierde soluciones válidas debido a tres razones [Mahfoud94]: presión en la selección, ruido en la selección y ruptura de los operadores. Para superar estos problemas se han desarrollado diferentes métodos que se describen muy brevemente a continuación.

**Índice de bondad repartida:** es la técnica usada con más frecuencia, y se basa en mantener subpoblaciones estables (nichos), de modo que los individuos en un nicho particular deben compartir sus recursos. El primero en plantear esta técnica fue Holland [Holland92], proponiendo que los individuos tuvieran un índice de bondad modificado, compuesto de dos medidas: la *función objetivo* y el *índice de la densidad de población del nicho* al que este individuo pertenece. Posteriormente se creó una función, denominada '*índice de bondad repartida*' que tuvo en cuenta ambos objetivos [Goldberg87]. La mayoría de los individuos se localizan en la vecindad de un cierto individuo y ven degradado su valor de ajuste. La vecindad está definida como ya se ha visto en términos de una distancia y en este caso está especificada por el denominado *radio del nicho*  $\sigma_{\text{nicho}}$ . Dependiendo de cómo esté definida la distancia se distinguen tres tipos de ajuste: en el espacio del individuo, en el espacio de decisión y en el espacio objetivo. Se demuestra que la elección de los fenotipos, como espacio de medida (espacio de decisión), es más eficiente que la elección de los genotipos (espacio del individuo) [Deb89a], [Deb89b]. En el primer caso se usa la métrica euclídea, y el segundo la distancia de Hamming. En los problemas multiobjetivo resulta muy útil escoger el espacio objetivo, ya que permite obtener el frente de Pareto [Horn93], [Horn94].

Posteriormente se planteó el **contador de nicho**, en forma de muestreo, reduciendo así el tiempo de computación [Goldberg92], un algoritmo de grupos ('*clustering*') que delimita los diferentes nichos de la población [Yin93], y también se propuso que el operador cruce actuara únicamente sobre los individuos de un mismo nicho [Spears94].

La mayoría de los MOEAs implementan el método del *índice de bondad repartido* [Hajela92], [Fonseca93], [Horn94], [Srinivas95], [Todd97], [Cunha97].

**Restricción en la reproducción ('*Restricted Mating*')**: a partir de la idea de que dos especies no se cruzan entre sí, en este caso sólo se permite reproducirse a dos individuos si están a una distancia menor de un valor determinado. Se mejora la ruptura de los operadores, pero no la presión y el ruido en la selección [Deb89a]. No se ha difundido demasiado en el ámbito de los MOEAs [Hajela92], [Fonseca93], [Loughlin97].

**Aislamiento por distancia:** este mecanismo de diversidad asigna a cada individuo una localización [Ryan95], y después se pueden distinguir dos posibilidades: o la población puede evolucionar en cualquier nicho, o cada nicho tiene poblaciones independientes que de vez en cuando intercambian individuos (proceso de migración) [Poloni95], [Laumanns98].

**Reinicialización:** para frenar la presión de selección se han desarrollado técnicas que incorporan a la población nuevos individuos (inmigrantes) en cada generación, consiguiendo una velocidad de convergencia mayor [Fonseca95b], [Fonseca98a].

**Agrupamiento ('Crowding'):** los nuevos individuos reemplazan a los individuos similares de la población. Aquí no toda la población se somete a la selección, recombinación y mutación, sino únicamente unos pocos individuos cada vez. Este algoritmo no genera diversidad en la población, sino que mantiene la diversidad que existía al inicio. Se ha propuesto un algoritmo de agrupamiento determinista, en el que se agrupa la población por parejas, se cruzan, y cada padre puede ser reemplazado por el hijo más similar [Mahfoud93], [Mahfoud94].

### 2.8.3.- Elitismo

El elitismo se propuso en 1975 [DeJong75], y se refiere a incluir siempre el mejor (o mejores) individuo en la población de la siguiente generación, para impedir así la pérdida de información que puede causar la destrucción de ese mejor individuo por el operador cruce. De Jong comprobó que el elitismo podía mejorar la convergencia de un GA con funciones unimodales, pero sin embargo podía provocar la convergencia prematura con funciones multimodales.

En la optimización multiobjetivo tiene un papel importante, y su implementación resulta más compleja. En este caso hay que responder a dos cuestiones:

1. Cuáles son los individuos que deben ser conservados y hasta cuándo.
2. Cuándo y cómo se deben reintroducir en la población.

Dos son las aproximaciones más habituales en la literatura. La primera aplica directamente la idea de De Jong. Incluye automáticamente los individuos no dominados en la población en la siguiente generación [Tamaki94]. Algunas veces se usa una variante más restrictiva, en la cual sólo se conservan los individuos que optimizan al menos uno de los objetivos [Anderson96], [Murata96], [Todd97], [Rudolph98].

También se emplea la estrategia de conservar un conjunto externo de individuos no dominados, que en cada generación reemplazan un porcentaje de la población, ya sea seleccionado aleatoriamente [Cieniawski95], [Ishibuchi96], o siguiendo algún criterio, como puede ser el tiempo que un individuo ha permanecido en la población [Parks98].

Los últimos trabajos aparecidos han demostrado que eliminar soluciones no dominadas del frente de Pareto puede hacer falsas las estimaciones sobre dicho frente [Everson02].

### 2.8.4.- Clasificación de los algoritmos multiobjetivo

En el ámbito multiobjetivo es posible clasificar el desarrollo de este tipo de metaheurísticas en tres grandes áreas: AGs sin elitismo, AGs con elitismo y AGs hibridizados con búsqueda local o también llamados, algoritmos meméticos (AM). En el primer grupo existe un enfoque de dominancia de soluciones como elemento de selección de cromosomas durante el proceso de búsqueda. De esta manera, los cromosomas dentro de una generación son divididos en grupos dentro de los cuales no existe dominancia. A cada grupo, se le asigna la misma función de adaptación o (fitness) debido a que no hay diferencia entre soluciones no dominadas. De esta manera se busca una convergencia hacia la formación de una frontera de Pareto como solución al problema. Este fitness puede ser modificado para privilegiar zonas de la frontera que se encuentran menos pobladas y evitar así la concentración de soluciones en zonas particulares de la frontera de Pareto, este fenómeno se denomina formación de nichos. El primer enfoque de AG multiobjetivo bajo este esquema corresponde a MOGA (Multi-Objective Genetic Algorithm) de Fonseca & Fleming [Fonseca93]. Posteriormente han surgido muchos AG multiobjetivos basados en este enfoque en el cual se utiliza la dominancia como elemento de búsqueda. Algunos ejemplos corresponden a Nondominated Sorting Genetic Algorithm (NSGA) [Srinivas95], y Niche-Pareto Genetic algorithm (NPGA) [Horn94].

En el segundo grupo el enfoque corresponde a técnicas que incorporan el elitismo dentro de su proceso de búsqueda. Generalmente estas técnicas mantienen una población externa en la cual se almacenan soluciones de elite, las cuales son introducidas en cada generación para mejorar la calidad de los cruzamientos entre cromosomas. Algunas técnicas dentro de esta categoría corresponden a Strength Pareto Evolutionary Algorithm (SPEA) [Zitzler99b], NSGA II [Deb02], MOMGA II [Zydallis01], SPEA II [Zitzler02], entre otros.

El tercer grupo corresponde a los algoritmos meméticos, los cuales corresponden a un área de la programación evolutiva en la cual se combinan dos tipos de mecanismos de búsqueda, como son, los algoritmos genéticos y la búsqueda local. La base filosófica que sustenta esta metaheurística radica en la idea de que un individuo es capaz de transformar información cultural, es decir aprendida durante su existencia, a un formato genético que le permita traspasar esta información a las generaciones siguientes por la vía biológica. Este concepto, es aprovechado para ser incorporado a la inteligencia artificial como un algoritmo genético tradicional, al cual se le incorpora algún tipo de mecanismo de búsqueda local. De esta manera, es posible hacer una analogía, en la cual el algoritmo genético representa el proceso evolutivo de los individuos y la búsqueda local se asocia a elementos culturales a los cuales cada individuo puede verse sometido durante su vida.

Es así como un cromosoma antes de pasar a la generación siguiente, puede tomar una forma diferente cuando se le incorpora información aprendida durante su existencia y puede traspasar a sus descendientes la información por la vía genética. Esta herramienta ha sido utilizada con éxito en diferentes tipos de problemas preferentemente del tipo combinatorio [Jaszkiewicz04]. En particular, aplicaciones en el ámbito multiobjetivo combinatorio es posible destacar el problema de la mochila [Ishibuchi03], cubrimiento de conjuntos [Jaszkiewicz04], vendedor viajero [Buriol04], problema de asignación cuadrática [Drezner03].



En el área de problemas combinatorios asociados a la programación de la producción también existen aplicaciones exitosas de algoritmos meméticos. La mayoría de los trabajos se concentran en el problema de taller de flujo (FlowShop) [Ishibuchi03].

En ésta tesis se ha trabajado con el segundo grupo, y en el siguiente apartado lo trataremos con mayor detalle.

#### 2.8.4.1.- Algoritmos multiobjetivo con elitismo.

Estos algoritmos se corresponden a una segunda generación de MOEAs, que transcurren desde 1999 a la actualidad. Se realizaron muchos avances teóricos en la fundamentación de estas técnicas, entre los que cabe destacar los siguientes:

- Se realizaron múltiples propuestas de problemas de prueba estándar, dentro de los que destacan:
  - ZDT (Zitzler, Deb, Thiele): proponen un mecanismo para generar problemas de prueba. Diseñan 6 problemas que fueron siguiendo su metodología (ZDT1 a ZDT6).
  - Otros problemas: Ozyczka, Golinski, Viennet.
- Se avanzó en propuestas para mejorar el desempeño computacional (MOEAs paralelos).
- Se propusieron métricas para la evaluación objetiva de los resultados obtenidos

La característica fundamental de estos algoritmos consiste en la incorporación de elitismo a los mismos. Se propusieron básicamente dos mecanismos de elitismo:

1. selección ( $\mu+\lambda$ ).
2. utilización de una población externa que es la encargada de almacenar las soluciones no dominadas.

Este último ha sido implementado por varios MOEAs de forma muy exitosamente.

En el caso de la **selección ( $\mu+\lambda$ )**, lo que se hace es unir la población de padres con la de hijos y jerarquizarla. A partir de esta nueva población, se elige sólo a los no dominados. Si se quisiera elegir a más individuos de los no dominados disponibles, el resto se puede seleccionar de los dominados. Si se desean seleccionar menos soluciones que las no dominadas de la población, puede usarse un criterio adicional para los desempates (p.ej., se puede preferir a una solución que esté en una región menos poblada del espacio de búsqueda).

Para el caso de una **población externa**, normalmente se implementa un archivo externo en el cual se colocan todas las soluciones no dominadas que se van encontrando a lo largo del proceso evolutivo. Sólo se inserta una solución al archivo si ésta es no dominada con respecto a su contenido. Si la solución insertada domina a una del archivo externo, esta última deberá ser eliminada.

Algunos aspectos a considerar en este último enfoque son los siguientes:

- La interacción entre la población y la población externa.
- Los criterios para realizar las inserciones de elementos en la población externa.

- Las acciones a tomar cuando se completa la población externa.
- El tamaño de los archivos.
- Estructura de datos para la implementación del archivo.

En la siguiente sección se presentan los algoritmos más representativos, haciendo un estudio más completo del SPEA-2 y el NSGA-2 que son los utilizados en este trabajo.

#### 2.8.4.1.1. - Strength Pareto Evolutionary Algorithm (SPEA).

El SPEA fue propuesto por Zitzler y Thiele en 1998 [Zitzler99b], utiliza una población externa de soluciones no dominadas obtenidas previamente. Se basa en el concepto de fuerza (strength) que tiene un rol similar al rango de dominancia en otros MOEAs. La fuerza de un individuo es proporcional al número de individuos que son dominados por él. Por tanto, la asignación de fitness se basa en la medida de “fuerza”. La diversidad se mantiene empleando técnicas de clustering.

#### 2.8.4.1.2. - Strength Pareto Evolutionary Algorithm (SPEA-2).

Desarrollado por Zitzler, Laumanns y Thiele en el 2000 [Zitzler02] con el fin de superar debilidades detectadas en el esquema de asignación de adaptación del SPEA [Zitzler00]. En este algoritmo, la función de asignación de aptitud se mejora teniendo en cuenta para cada individuo el número de individuos a los que domina y el número de individuos por los que es dominado [Dias02]. Este esquema también añade una estimación de densidad poblacional. El tamaño  $N_{E_{max}}$  de la población externa  $P_E$  utilizada para realizar el elitismo es fija, a diferencia del SPEA, en el cual el tamaño de  $P_E$  es variable pero acotado.  $P_E$  está conformada sólo por individuos no dominados siempre y cuando el número de éstos sea mayor o igual que  $N_{E_{max}}$ . En el caso en que el número de individuos no dominados sea menor que  $N_{E_{max}}$  se incluyen individuos dominados dentro de  $P_E$  hasta que el tamaño de  $P_E$  sea igual a  $N_{E_{max}}$ . La técnica de agrupamiento (clustering), encargada de mantener la diversidad de la población en SPEA, es sustituida por un método de truncamiento, el cual evita eliminar las soluciones extremas del conjunto de soluciones no dominadas. La selección se realiza mediante torneo binario, tomando como criterio de comparación el fitness de cada uno de los individuos. SPEA-II asume minimización de fitness, por lo tanto gana el torneo aquel individuo que tenga un menor valor de fitness.

---

#### Algoritmo 2.4: SPEA-2

---

Inicio

**Para** (cada  $t \in T$ ) haga

**Mientras** Que (exista una ruta del nodo  $s$  a nodo  $t$ ) haga

Rutas  $\leftarrow$  Ruta desde  $s$  hasta  $t$

**Fin** Mientras Que

**Fin** Para

Generar aleatoriamente  $P_0$

Hacer  $P_E \leftarrow \emptyset$

Hacer  $t \leftarrow 0$

**Mientras** Que  $t < g_{max}$  y Cont\_Convergencia  $< g_{conv}$

Calcular el número de saltos y el retardo de los miembros de  $P^t$  y  $P_E^t$

Calcular el *fitness* de cada uno de los individuos en  $P^t$  y  $P_E^t$

Realizar un proceso de selección ambiental para conformar la nueva población externa  $P_E^{t+1}$

Aplicar el operador de selección por torneo binario con reemplazo sobre  $P_E^{t+1}$

Aplicar los operadores de cruce y mutación sobre la población seleccionada.

Asignar la nueva generación a  $P^{t+1}$ .

Hacer  $t \leftarrow t + 1$

**Fin** Mientras Que

**Fin**

---

En resumen las principales características del SPEA-2 son:

- la asignación de fitness considera la cantidad de individuos dominados por cada solución (como SPEA), pero además toma en cuenta la cantidad de individuos que la dominan.
- para mantener diversidad utiliza una técnica de estimación de densidad de individuos vecinos.
- utiliza un esquema de truncamiento de la población externa que le garantiza la preservación de soluciones de frontera (bordes).

#### 2.8.4.1.3. - Pareto Archived Evolution Strategy (PAES).

Éste fue propuesto por Knowles en 1999 [Knowles99], sus características más importantes son las siguientes:

- Es uno de los métodos más simples, ya que incorpora el elitismo mediante una selección (1+1).
- Utiliza un archivo histórico de individuos no dominados.
- Realiza una división del espacio de funciones objetivo aplicada en forma recursiva, generando una rejilla adaptativa.
- Para preservar la diversidad utiliza crowding, evaluando las soluciones en cada uno de los cuadrantes de la rejilla

Algunas aplicaciones de esta técnica son las siguientes: Problemas de telecomunicaciones [Knowles99] Manejo de bases de datos distribuidas adaptativas [Knowles00].

---

#### Algoritmo 2.5: PAES

---

Inicio

Creamos Población de un único padre  $p$  y se añade al archivo.

mutamos  $p$  para producir un hijo  $c$  y evaluamos el fitness

**if** ( $p$  domina  $c$ ) discard  $c$

else **if** ( $c$  domina  $p$ )

reemplaza  $p$  con  $c$ , y añade  $c$  al archivo

**else if** (**if**  $c$  es dominado por un elemento del archivo)

descartar  $c$

**else** aplicar test (p,c,Archivo) para determinar cual se convierte en la nueva solución, que será agregada al archivo.

Hasta que un criterio de terminación sea cierto, volver a la línea 2

#### 2.8.4.1.4. - Non-dominated Sorting Genetic Algorithm-II (NSGA II).

Propuesto por Deb, Agrawal, Pratap y Meyarivan en el 2000 [Deb02], con el fin de incorporar elitismo y reducir la complejidad del procedimiento de ordenamiento rápido por no dominancia de su antecesor. Realiza una clasificación de la población por frentes. Los individuos que pertenecen al primer frente son los no dominados; los que pertenecen al segundo frente son los no dominados en ausencia de los del frente anterior, y así sucesivamente. A cada individuo se le asigna un rango equivalente a su nivel de no dominancia. Los mejores individuos son aquellos que tienen rangos menores. También incorpora el cálculo de una distancia de crowding, como el operador utilizado para mantener la diversidad de la población, con el fin de evitar el uso del  $\sigma_{share}$  en la compartición de aptitud (fitness sharing) de su antecesor. La selección es realizada mediante torneo binario, utilizando como criterio de comparación el operador  $\succ_n$ . Según este criterio, el torneo lo gana el individuo con menor rango. Si el rango es el mismo, el torneo lo gana aquel individuo que tenga menor distancia crowding.

El pseudocódigo 1 muestra el NSGA-II en su forma general.

#### Algoritmo 2.6: NSGA-2

##### Inicio

**Para** (cada  $t \in T$ ) haga

**Mientras** Que (exista un ruta del nodo s a nodo t) haga

Conjunto\_Rutas  $\leftarrow$  Ruta desde s hasta t;

**Fin** Mientras Que

**Fin** Para

Generar aleatoriamente  $P_0$

Hacer ordenamiento rápido no dominado de  $P_0$

Aplicar los operadores de selección, cruce y mutación para generar una población hija  $Q_0$

Hacer  $t \leftarrow 1$

Hacer  $R_t \leftarrow \emptyset$

**Mientras** Que  $t < g_{max}$  y Cont\_Convergencia  $< g_{conv}$

Hacer  $R_t \leftarrow P_t \cup Q_t$

Calcular el número de saltos y el retardo de los miembros  $R_t$

$F \leftarrow$  OrdenamientoRápidoNoDominado ( $R$ )

**Mientras** Que (  $|P_{t+1}| < N$  ) hacer

CalcularDistanciaCrowding ( $F_i$ )

$P_{t+1} \leftarrow P_{t+1} \cup F_i$

**Fin** Mientras Que

Ordenar  $P_{t+1}$  en forma descendente, utilizando el operador  $\succ_n$

Escoger los N primeros elementos de  $P_{t+1}$ .

Generar  $Q_{t+1}$ , aplicando los operadores de selección cruce y mutación sobre

$P_{t+1}$ .

Hacer  $t \leftarrow t + 1$   
**Fin** Mientras Que  
**Fin**

---

Las características fundamentales del NSGA-2 son las siguientes:

- No utiliza población secundaria.
- Incorpora elitismo mediante un esquema de selección  $(\mu+\lambda)$ .
- El chequeo de dominancia fue mejorado para aumentar la performance computacional.
- En lugar de la técnica de sharing del NSGA, utiliza un mecanismo de crowding que no requiere parámetros.
- En general funciona mejor para representación real que para representación binaria.
- Es uno de los algoritmos que en la práctica ha mostrado mejores resultados.

#### **2.8.4.1.5.- Niched-Pareto Genetic Algorithm (PESA y PESA-2).**

PESA utiliza la rejilla adaptativa de PAES para mantener la diversidad [Corne00]. Sin embargo, el mecanismo de selección está basado en la medida de agrupamiento (crowding) usada por la rejilla auto-adaptativa. Esta misma medida se usa para decidir qué soluciones ingresan al archivo externo.

PESA-II fue propuesto por Corne et al. en 2001. Su única diferencia con respecto a PESA es que se usa una selección basada en regiones. En este esquema de selección, la unidad de selección es la hiperrejilla en vez del individuo. Esto busca reducir el coste computacional.

Algunas aplicaciones de esta técnica son las siguientes: Problemas de telecomunicaciones [Corne00].

#### **2.8.4.1.6.- Multi-Objective Messy Genetic Algorithm (MOMGA y MOMGA-2).**

MOMGA fue propuesto por David Van Veldhuizen en 1999. Este algoritmo es un intento por extender el Messy GA de manera que pueda lidiar con problemas multiobjetivo. MOMGA consta de 3 fases:

1. Fase de Inicialización.
2. Fase Primordial.
3. Fase Yuxtaposicional.

En la Fase de Inicialización, MOMGA produce todos los bloques constructores de un cierto tamaño pre-especificado usando un procedimiento determinista conocido como inicialización parcialmente enumerativa. Durante la Fase Primordial se efectúa una selección mediante torneo en la población y se reduce su tamaño de ser necesario. En la Fase Yuxtaposicional, se procede a construir la población nueva a través del uso de los operadores de corte y empalme.

Zydallis et al, propusieron el MOMGA-II en el 2001 [Zydallis01]. La principal diferencia del MOMGA-II con respecto a su antecesor radica en las primeras dos fases. La Fase de Inicialización utiliza un proceso de inicialización probabilístico que crea un número controlado

de clones de los bloques constructores de un cierto tamaño predeterminado. La Fase de Filtrado de Bloques constructores reduce el número de bloques a través de un proceso de filtrado y almacena los mejores bloques constructores obtenidos. La Fase Yuxtaposicional es la misma del MOMGA.

Algunas aplicaciones de esta técnica son las siguientes: Diseño de controladores [Herreros00], Funciones de prueba tradicionales [Van00], Funciones de Prueba tradicionales [Zydallis01].

#### **2.8.4.1.7. - Niched-Pareto Genetic Algorithm (NPGA II).**

Es una versión mejorada del NPGA propuesta por Erickson et al. en 2001 Erickson01, sus principales características son las siguientes:

- Utiliza jerarquización de Pareto pero mantiene la selección mediante torneo.
- Incorpora elitismo mediante un esquema de selección ( $\mu+\lambda$ ).
- Utiliza sharing mediante el conteo en los nichos de individuos de la siguiente generación (partial niching). Esta propuesta se basa en la idea de continuously updated fitness sharing propuesta por Oei en 1991.

Algunos usos de esta técnica son los siguientes: Contaminación de acuíferos [Erickson01].

#### **2.8.4.1.8. - Micro Genetic Algorithm for Multiobjective Optimization (Micro GA).**

El micro genetic algorithm que propusimos para optimización multiobjetivo es uno de los algoritmos multiobjetivo más rápidos de la actualidad, superando en varios órdenes de magnitud a algoritmos tan eficientes como el NSGA-II. La versión original del microGA se presentó en la primera conferencia internacional de optimización multi-objetivo (EMO'01).

El mayor inconveniente del Micro GA es que requiere un elevado número de parámetros, ocho en concreto, de los cuales al menos 3 son críticos para su desempeño.

El Micro Genetic Algorithm for Multiobjective Optimization (Micro GA) fue propuesto por Toscano y Coello en 2001. Sus características más importantes son:

- Utiliza una población muy pequeña e incorporar un mecanismo de reinicialización cuando se alcanza la convergencia.
- Utiliza dos poblaciones, una reemplazable y otra no, para gestionar la dominancia y la diversidad.
- La incorporación del elitismo se basa en la idea de mantener soluciones no dominadas pero con una memoria que se actualiza a plazos.
- Utiliza la grilla adaptativa de PAES.

Algunas aplicaciones de esta técnica son las siguientes: Diseño de aviones [Chung03], Diseño estructural [Coello02], Particiones de sistemas de hardware/software [Fornaciari03].

#### **2.8.4.1.9. – Algoritmo multi-objetivo MoCell.**

Éste es una versión mejorada de cMOGA, por lo que es también una adaptación de un cGA canónico al campo multi-objetivo. MOCell [Nebro09] utiliza un archivo externo para almacenar las soluciones encontradas no dominadas durante la ejecución del algoritmo, como hacen

muchos otros algoritmos evolutivos multi-objetivo (por ejemplo, PAES, SPEA2, o cMOGA). La característica principal que diferencia a MOCeII con respecto a estos algoritmos es la realimentación de individuos desde el archivo que se realiza después de cada iteración, reemplazando a algunos individuos de la población actual seleccionados de manera aleatoria.

Se puede observar el pseudocódigo en el Algoritmo 2.7. Una de las principales diferencias con un cGA es la existencia de un frente de Pareto en el caso del multi-objetivo. Éste es sólo una población adicional (el archivo externo) compuesto por un número de soluciones encontradas no dominadas, ya que tiene un tamaño máximo. Para la gestión del archivo se utiliza un estimador de densidad basado en la distancia de crowding (propuesto en NSGA-II [Deb02]). Este método también se usa para eliminar las soluciones del archivo cuando se llena.

---

**Algoritmo 2.7 MOCeII.**

---

```
proc Evolucionar(mocell)           //Parámetros del algoritmo en `mocell`
Frente pareto = Crear Frente() //Crea un frente de Pareto vacío
mientras !CondiciónParada() hacer
    para individuo ← 1 hasta mocell.Tamaño Población hacer
        vecinos ← ObtenerVecindario(mocell,posición(individuo));
        padres ← Selección(vecinos);
        descendiente ← Recombinación(mocell.Pc,padres);
        descendiente ← Mutación(mocell.Pm,descendiente);
        Evaluar(descendiente);
        Insertar(posición(individuo),descendiente,mocell,poblac auxiliar);
        InsertarFrentePareto(individuo, Frente pareto);
    fin para
    mocell.poblac ← poblac auxiliar;
    mocell.poblac ← Retroalimentar(mocell,Frente Pareto);
fin mientras
fin proc Evolucionar;
```

---

MOCeII empieza creando un frente de Pareto vacío (línea 2 del Algoritmo 2.7). Los individuos se sitúan en una rejilla toroidal de 2 dimensiones, y se les va aplicando sucesivamente el ciclo reproductor (líneas 4 a 12) hasta que se alcanza la condición de parada (línea 3). Así, para cada individuo, el algoritmo consiste en seleccionar dos padres de su vecindario, recombinarlos para obtener un descendiente, mutarlo, evaluar el individuo resultante e insertarlo tanto en la población auxiliar (si no está dominado por el individuo actual) como en el frente de Pareto. Finalmente, después de cada generación, se reemplaza la población antigua por la auxiliar (línea 13), y se invoca un proceso de realimentación para reemplazar un número fijo de individuos de la población escogidos aleatoriamente por soluciones del archivo (línea 14). Además se ha incorporado el mismo mecanismo que utiliza el NSGA-II para tratar las restricciones de aquellos problemas que las posean. Éste consiste en que el individuo que viole un menor número de soluciones se considera mejor, y a igualdad de restricciones insatisfechas los individuos se comparan en función del valor de fitness.

## 2.9 Conclusiones

En este capítulo se recogen los conceptos fundamentales relacionados con los algoritmos evolutivos. En él se han tratado las definiciones de optimización global y optimización multiobjetivo, y se ha descrito lo qué se entiende por complejidad computacional y qué es la heurística. Posteriormente se han explicado los distintos métodos de optimización y se ha ofrecido una clasificación de los mismos. Se ha podido observar que Los métodos heurísticos, entre los que se integran los algoritmos evolutivos (EAs), han asumido gran protagonismo en la resolución de problemas de gran complejidad, especialmente aquéllos que son NP-completos.

A continuación se han revisado los conceptos teóricos básicos sobre algoritmos evolutivos. Inicialmente se trata de forma breve su historia y después se repasan los fundamentos y terminología básica. También se explica cómo se aplican éstos para resolver problemas multiobjetivo, introduciendo los conceptos de selección y ajuste, diversidad de la población y elitismo. En el último capítulo se introducen de forma más detallada los algoritmos multiobjetivo con elitismo, qué son los utilizados en éste trabajo para el desarrollo de la aplicación de gestión de estrategias de “trading”.

En resumen, en éste capítulo se han tratado los fundamentos básicos sobre algoritmos evolutivos, poniendo especial énfasis en los necesarios para el desarrollo de la herramienta de “trading” que se expone en ésta tesis.





## **3. Aplicación de los algoritmos evolutivos para la gestión de estrategias de “trading”**

---

### **3.1 Introducción**

### **3.2 Selección de parámetros, complejidad intrínseca**

### **3.3 Objetivos planteados para el problema de optimización multiobjetivo**

### **3.4 Análisis del conjunto de datos de experimentación**

### **3.5 Sistemas de negociación de alta frecuencia**

### **3.6 Conclusiones**

---

En el primer apartado se realiza una introducción a los objetivos principales de un inversor, para continuar con la arquitectura del sistema propuesto y sus componentes fundamentales.

Posteriormente, se explica en profundidad los distintos cromosomas que conforman el gen, así como sus restricciones operacionales. A continuación se exponen los objetivos planteados para el problema de optimización multiobjetivo.

En el siguiente apartado se han analizado los conjuntos de datos que se utilizarán en los experimentos del siguiente capítulo.

Finalmente se tratan brevemente los sistemas multifrecuencia, explicando a través de un experimento los objetivos que persiguen, y que se ajustan al sistema presentado en éste trabajo.

### 3.1.- Introducción.

Los inversores utilizan distintas estrategias para la consecución de sus objetivos. Estas se apoyan, en el caso del análisis técnico, en los indicadores técnicos, que como se vio en capítulos anteriores, siguen la serie temporal de precios para la realización de predicciones. En este trabajo se utilizarán algoritmos evolutivos para la optimización de éstas estrategias, las cuales, como veremos más adelante, no están únicamente constituidas por estos indicadores. El objetivo principal de un interviniente en el mercado es obtener ganancia a partir de una inversión realizada, pero no es el único (es un problema multiobjetivo), y además, pueden confluir de manera simultánea. Veamos brevemente los más importantes:

- **Maximizar el beneficio:** para ello es necesario en primer lugar una toma de decisión correcta, ya que si el mercado se mueve en sentido contrario a nuestra opción no se obtendrán ganancias. Por otra parte, también hay que tener un buen control de los momentos de entrada y salida en el mercado. Por ejemplo, una entrada tardía o una salida demasiado temprana pueden generar pérdidas, en un entorno operativo inicialmente propicio. Otro elemento importante es la optimización de la reinversión de los beneficios.
- **Minimizar el riesgo:** el inversor necesita operaciones estables, que le permitan obtener beneficios. Esto se consigue con sistemas que minimicen la desviación en sus operaciones y limiten al máximo el número de operaciones fallidas de forma consecutiva. Es posible que una estrategia ganadora, en algún instante de la operativa, realice un número de operaciones fallidas que dejen al inversor en número rojos, y sin la capacidad de poder seguir invirtiendo. En éste punto, es fundamental la gestión del capital, conocer cuánto hay que invertir, en qué estrategia, en un momento determinado, sin correr el riesgo de una gran pérdida. Aquí hay que tener en cuenta que el mercado cambia constantemente y en ocasiones lo hace de una forma violenta cómo con el anuncio de un terremoto, una guerra etc.
- **Maximizar el rendimiento:** el rendimiento va ligado al número de veces que entramos en el mercado, y por tanto, a los intereses que se abonan por el capital prestado y a las comisiones que recibe el bróker en cada nueva operación. Mantener operativas abiertas durante una gran cantidad de tiempo generará muchos intereses (swap), que pueden mermar de una manera considerable la ganancia. Las comisiones (spread) que cobra el intermediario por intervenir en el mercado, hacen que algunas operaciones no sean rentables por el bajo margen de ganancia. En resumen, el objetivo es entrar el mayor número de veces posible, pero mantenerse dentro sólo hasta el momento en el que se obtiene la máxima ganancia. Si la operación que se inicia no resulta positiva es mejor abandonar lo antes posible, y buscar nuevas tentativas. Un buen inversor busca optimizar constantemente el coste de oportunidad. Normalmente, una maximización de rendimiento lleva consigo la obtención de un mayor beneficio.

Como se puede observar, las estrategias que conforman un sistema de “trading” tienen distintos objetivos, y por tanto, se trata de problemas de optimización multivariable y multiobjetivo, y cómo se verá en éste capítulo, debido a su complejidad (es NP-completo), no son aptos para ser solucionados mediante métodos clásicos de optimización.

Durante toda la investigación previa, se obtuvieron los conocimientos y datos necesarios para establecer la arquitectura de la aplicación de “trading” en divisas con algoritmos evolutivos en tiempo real, cuyas características y descripción se muestran a continuación. Para comprobar su robustez y obtener resultados más reales, se han efectuado estudios experimentales sobre una cuenta demo, que puede ser representativa de cualquier bróker online que opere actualmente en el mercado.

### 3.1.1.- Descripción de la arquitectura

La arquitectura de la aplicación se compone de cuatro módulos (figura 8), el gestor de extracción de datos, el gestor de soluciones, el gestor de expertos y el gestor de capital (Figura 7). De forma resumida cada uno de ellos realiza las siguientes tareas:

- **Gestor extractor de datos (Módulo I):** extrae y almacena los datos correspondientes a la serie temporal de precios (“tick” a “tick”). Estos datos son posteriormente procesados y guardados en distintos espacios temporales. Este elemento es fundamental, ya que recoge toda la información para el análisis posterior. En este caso es del orden de una entrada de datos cada dos segundos.
- **Gestor de soluciones (Módulo II):** utiliza los algoritmos evolutivos, junto con la estrategia de “trading”, para la obtención de soluciones óptimas. Este gestor se ha creado de manera configurable para operar con distintos algoritmos evolutivos. Las soluciones obtenidas sirven de base para cálculos en éste módulo y en el siguiente. En la Figura 7, se puede observar el conjunto de soluciones que conforman el frente de Pareto generado por el módulo en un instante de funcionamiento del sistema. Normalmente, el número de soluciones con las que opera el sistema de forma simultánea, en media, está entre ochenta y ciento veinte, y depende de la volatilidad del mercado. Para entornos volátiles se reduce, y aumenta para estables.




Figura 7.- Frente de Pareto multiobjetivo

Con la llegada de nuevos datos éste frente se va recalculando, desechando aquellas soluciones dominadas por otras nuevas. En general la variación es pequeña, lo que indica la robustez del sistema, aunque como se indicaba anteriormente está ligado a la volatilidad. El tiempo de recalcu lo está fijado por el número de evaluaciones que ejecuta el algoritmo evolutivo.

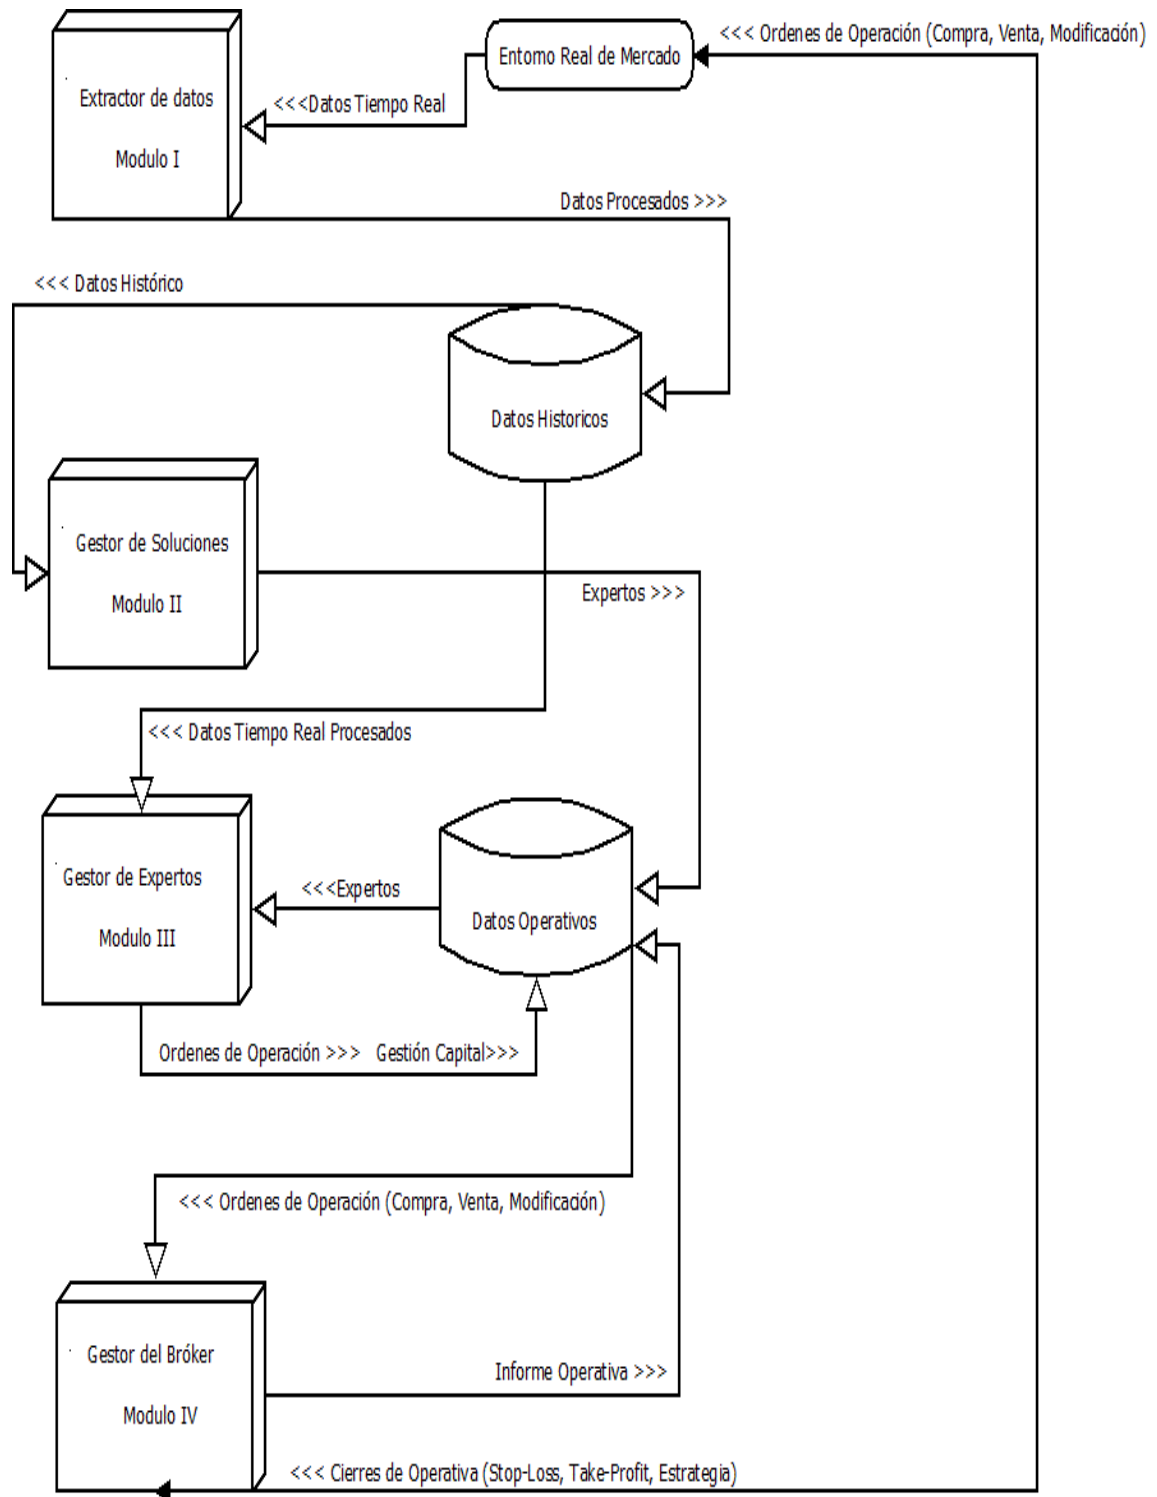


Figura 8.- Arquitectura del Sistema

**Gestor expertos (Módulo III):** este módulo es el motor de la operativa en tiempo real y tiene un doble objetivo, gestionar el capital, y monitorizar los expertos para la toma de decisiones. Las soluciones obtenidas con anterioridad son primeramente evaluadas para una gestión de capital óptima. Es decir, se añade la cantidad de lotes con los que ésta operará cuando entre al mercado. Esta información es dinámica, y se recalcula constantemente en función del grado de acierto obtenido en la operativa anterior. Una vez realizada esta acción, las soluciones se denominan expertos, y son añadidas a la lista de expertos operativos. A partir de aquí, cada vez que se produce un nuevo tick, se comprueba si se genera algún tipo de señal por parte de los expertos activos, y si es el caso, se inicia una orden que se almacena en el repositorio, para ser posteriormente cursada por el gestor del bróker. El tiempo que transcurre desde que el gestor inicia la orden hasta que ésta es ejecutada es de un segundo aproximadamente. Toda la información generada en este proceso se almacena para su posterior procesamiento.

**Gestor bróker (Módulo IV):** es el lugar donde se abren y cierran las operaciones reales, y está sincronizado en todo momento con el gestor de expertos. Las órdenes de apertura o cierre son almacenadas en base de datos por parte del gestor experto y recogidas por éste para su ejecución en el mercado. En éste trabajo se ha utilizado principalmente metatrader 4.0 [www-metatrader] junto con su lenguaje de programación mql4 [www-mql4] para llevar a cabo ésta gestión. También se ha probado el api en java que provee dukascopy [www-dukascopy]. En cualquier caso, la operativa relacionada con la toma de decisiones se ha realizado independiente del bróker online que se pudiera utilizar. Estos programas no están restringidos únicamente al mercado de divisas, lo cual permite una escalabilidad del sistema hacia otro tipo de valores.

En los siguientes apartados vamos a estudiar los parámetros que componen las soluciones que genera el algoritmo evolutivo y los objetivos que se desea que cumplan. En este caso, éstas vienen determinadas por la estrategia y objetivos seleccionados.

## 3.2. Selección de parámetros, complejidad intrínseca

Según distintos autores [Murphy09], las mejores estrategias de “trading” se generan a partir de la combinación de dos indicadores, un seguidor de tendencias y un oscilador. Siguiendo ésta recomendación se ha elaborado la estrategia base utilizada en éste trabajo. Los indicadores seleccionados han sido el MACD y el estocástico [Elder93]. El primero de ellos nos indicará la tendencia del sistema, la denominada “mareas”, mientras que el segundo detectará las mejores opciones para operar siguiendo la tendencia anterior, también denominado “la ola”. Ambos indicadores son explicados en la sección de indicadores técnicos (sección 1.3).

La selección de éstos en ningún caso expresa la mejor combinación posible de indicadores, este estudio se escapa al alcance de esta tesis. Aunque tampoco supone una limitación para la misma, ya que lo que se intenta demostrar es como la optimización de una estrategia, a través de algoritmos evolutivos, mejora ampliamente las expectativas, y esto podría ser aplicable de una forma generalizada a cualquier estrategia de “trading”.

### 3.2.1 Generación de señales de entrada y salida al mercado de los indicadores.

Como se indicó anteriormente, el MACD seguirá la tendencia y el estocástico obtendrá las mejores oportunidades de entrada. En la Figura 9, se puede observar como los indicadores

propuestos generaran señales para la entrada de órdenes en el mercado. Por ejemplo, si la tendencia de la ventana temporal del MACD muestra tendencia alcista (Figura 9, izquierda), el mejor punto de entrada será cuando el indicador estocástico indique que el valor está sobrevendido. En la segunda imagen (Figura 9, derecha), se muestra el momento en el que se hace efectiva la señal de venta en el caso de que la tendencia sea bajista.




Figura 9.- Tendencia alcista y bajista.

Por tanto, las operaciones son siempre abiertas por las señales generadas por los indicadores. En la Tabla 4 se observan las señales que genera el sistema.

MACD	Tendencia Alcista (BUY)	Tendencia Bajista (SELL)
Estocástico		
Señal de Compra a largo (Sobrevenido)	BUY	NADA
Señal de compra a corto (Sobrecomprado)	NADA	SELL

Tabla 4.- Órdenes de entrada según las señales generadas por los indicadores.

Por otra parte, el cierre de las mismas se debe a dos eventos distintos, **nuevas señales de entrada o condiciones de mercado**.

En el caso de **nuevas señales**, la operativa se puede observar en la Tabla 5. Por ejemplo, si la operación abierta es de compra a corto (SELL), y el sistema genera una señal de compra a largo (BUY), entonces se cierra la operación actual. Si la señal de compra a largo (BUY) se mantiene, y dado que no existe ninguna operación abierta en este instante, se generará una operación de compra a largo (BUY). En el caso de que no existan señales, las operaciones se mantienen.

Operación Abierta	Ninguna	BUY	SELL
Señal			
Ninguna	MANTENER	MANTENER	MANTENER
Señal de Compra a largo(BUY)	BUY	MANTENER	CLOSE
Señal de compra a corto(SELL)	SELL	CLOSE	MANTENER

Tabla 5.- Señales de cierre para ordenes abiertas.

El otro caso de cierre se debe a lo que se denomina **condiciones de mercado**. Cuando una orden se introduce, ésta lo hace con una serie de parámetros que indican en qué condiciones de mercado puede ser cerrada. Una orden típica que se envía a un bróker online podría ser la siguiente:



OrderSend(Symbol(),OP\_BUY,Lots,Ask,3,"stop-loss",TakeProfit,"macd sample",16384,0,Green)

En ella se puede observar tanto el "stop-loss" como el take-profit. El primero cierra la orden para cubrir pérdidas y el segundo para la toma de beneficios. Ambos han sido definidos en el apartado de definiciones (sección 1.4). El valor de éstos, en el mercado de divisas, se mide en números enteros equivalentes a "PIPS". En la Tabla 6 se ha incluido el significado de todos los parámetros que componen una orden.

Parámetro	Significado
Symbol	El valor que se negocia, en este trabajo "EUR/USD"
Cmd	Tipo de operación, para el ejemplo compra
Volumen	Numero de lotes
Precio	Precio solicitado para la operación
Slippage	Máxima desviación para órdenes de compra o venta. Ésta representa la diferencia entre el precio que estamos viendo en nuestra plataforma comercial (bróker online) y el precio de la ejecución real
"stop-loss"	Nivel de pérdida máxima
Take-profit	Nivel de toma de beneficios
Comentario	Comentarios en formato de texto de la orden.
Magic	Es un número que sirve de identificador de la orden
Expiración	Tiempo de expiración de una orden
Color de línea	Este color se utilice para el seguimiento de la operación.

Tabla 6.- Parámetros de una orden.

En la operativa normal, el take-profit se mantiene fijo, mientras que el "stop-loss" se suele hacer dinámico ajustando su valor. Para ello, se introduce un nuevo parámetro denominado "trailing-stop", el cuál como se puede observar no se encuentra incorporado en la propia orden. El valor que toma éste es un número entero, generalmente en "pips". Cuando la orden alcanza una ganancia correspondiente a éste valor se envía una orden de modificación de la anterior variando el valor del "stop-loss", en el sentido que se produce el beneficio. Esto permite consolidar las órdenes, y en caso de que el mercado se dé la vuelta, no se pierda todo lo ganado. La mayor parte de los cierres se producen debidos a "stop-loss", y gracias a que son dinámicos éstos se realizan con ganancias. En el sistema desarrollado esta operativa se realiza en el **Gestor bróker**. Por tanto, en condiciones normales, cuando el mercado está a nuestro favor, la operación se cierra al alcanzar el take-profit, mientras que si éste es desfavorable lo hará cuando llegue al "stop-loss", cubriendo la posición, y minimizando las pérdidas.

En resumen, la creación de **una nueva operación** es debida a la estrategia, mientras que su cierre se puede deber a una **nueva señal**, que genera ésta, o a las **condiciones de mercado**.

### 3.2.2. Generación interna de señales por parte de los indicadores.

En el apartado anterior se ha visto en qué condiciones se generan las señales de compra-venta. En éste se va a observar como los indicadores las generan de manera interna. En la Tabla 7 se pueden ver los criterios para la generación de señales por parte del MACD.

Señal	Criterio	Descripción
Compra MACD (Se tienen que dar todos los	//Criterio 1 Principal0 < 0;	La línea principal está por debajo del cero.
	//Criterio 2	El valor de la línea principal anterior, menos la

criterios para que se genere la señal)	principal-0-principal1 > MACDpa	línea principal actual, es menor de una distancia denominada MACDpa (ver Figura 11).
	//Criterio 3 Principal2 > Principal1 Principal1 < Principal0	Este criterio recoge el cambio de tendencia entre tres datos de la línea principal (ver Figura 10). Esto hace que la señal sea más fuerte.
Venta MACD (Se tienen que dar todos los criterios para que se genere la señal)	//Criterio 1 Principal > 0;	La línea principal está por encima del cero.
	//Criterio 2 Principal1-principal-0 > MACDpb	El valor de la línea principal actual menos la línea principal anterior es menor de una distancia denominada como MACDpb (ver Figura 11).
	//Criterio 3 Principal2 < Principal1 Principal1 > Principal0	Este criterio recoge el cambio de tendencia entre tres datos de la línea principal (ver Figura 10). Esto hace que la señal sea más fuerte.

Tabla 7.- Criterios para la generación de señales.

En la Figura 10, se puede observar un intervalo de operativa del mercado, en éste caso referido a una ventana temporal de una hora. La parte de arriba muestra la serie de precios, mientras que la de abajo el indicador MACD. En ella, se puede observar como el indicador MACD reacciona a los diferentes cambios que se producen sobre la tendencia en los precios. En el primer caso, se produce un cambio a una tendencia bajista, esto hará que se activen los criterios 1 y 3 de venta, con la consiguiente señal. En el segundo caso, los precios adquieren una tendencia alcista, activándose los criterios de compra y produciendo una señal en éste sentido. Los criterios que generan ambas señales están resumidos en la Tabla 7.



Figura 10.- Detalle cambio de tendencia indicador MACD ( Figura generada con Metatrader 4.0).

Además de las condiciones anteriores, y para evitar señales demasiado adelantadas, se han fijado dos nuevos criterios, uno para cada posible operativa. Ambos han sido catalogados en el código como criterio 2 (ver Tabla 7). En la Figura 11, se recoge el detalle de su funcionamiento. Cuando los precios entran en una tendencia bajista, será evaluada la diferencia entre la barra perteneciente al periodo en el que se produce el cambio de tendencia y la siguiente, a este valor lo denominaremos MACDpa, de igual modo se hará en el caso de que los precios sufran una tendencia bajista, pero en éste caso el parámetro lo denominaremos MACDpb. Estos parámetros hacen que sea el algoritmo evolutivo el que evalúe la sensibilidad que debe tener

el sistema. Esto también resulta una innovación en éste trabajo, ya que en la mayoría de los casos es fija, obviando los parámetros que configuran el MACD. También indicar que éste conocimiento ha sido incorporado después de múltiples experimentos donde se observó que era necesario controlar la sensibilidad con la que el indicador producía las señales.



Figura 11. Significado gráfico de los parámetros MACDpa y MACDpb ( Figura generada con Metatrader 4.0).

En la Figura 12, se puede observar la serie de precios para una ventana temporal de una hora, junto con el indicador estocástico. En ella, se puede ver cómo se comporta éste conforme se van produciendo los cambios sobre la tendencia en los precios. En el caso de que ambas señales alcancen la zona de sobrecompra, el criterio interno  $EST_{pa}$  generará una señal de venta, mientras que si alcanzan la zona de sobreventa, el criterio interno  $EST_{pb}$  generará una señal de compra. En la Tabla 8 se pueden observar los criterios para la generación de señales por parte del Estocástico.




Figura 12.- Indicador Estocástico ( Figura generada con Metatrader 4.0).

Señal	Criterio	Descripción
Compra Estocástico (Se tienen que dar todos los criterios para que se genere la señal)	$EST_{pa} = \text{Zona de Sobreventa.}$  $\%K < EST_{pa}$ $\%D < EST_{pa}$	Las dos líneas del estocástico están por encima de la línea de referencia que marca la zona de sobreventa. La línea de referencia será el parámetro $EST_{pa}$ (ver <b>¡Error! No se encuentra el origen de la referencia.</b> ).

Venta Estocástico (Se tienen que dar todos los criterios para que se genere la señal)	ESTpb = Zona de Sobrecompra. %K > ESTpb; %D > ESTpb;	Las dos líneas del estocástico están por encima de la línea de referencia que marca la zona de sobrecompra. La línea de referencia será el parámetro ESTpb (ver <b>¡Error! No se encuentra el origen de la referencia.¡Error! No se encuentra el origen de la referencia.</b> ).
--	--	---

Tabla 8.- Detalle Criterios del Estocástico.

### 3.2.3.- Selección de los cromosomas que compondrán el gen para cada individuo.

Según lo anterior los genes estarán compuestos de los siguientes cromosomas.

#### 3.2.3.1.- Cromosomas relacionados con los indicadores.

El MACD consiste de dos líneas: La primera de ellas se realiza con la resta de dos medias móviles exponenciales (MME), y será la encargada de responder a los cambios de precios de una forma relativamente rápida. La segunda, denominada línea de señal, es la media móvil anterior, pero alisada, y que responde a los cambios de precios más lentamente. El valor clásico utilizado para este indicador es (12, 26, 9).

El Estocástico lento también se compone de dos líneas: una rápida denominada %K, y una lenta llamada %D. Una vez que se obtiene el %D, éste se pasa a %K, el cual a su vez se alisa para obtener el nuevo %D. El valor clásico de este indicador es (14, 3, 3).

Esto constituye un total de 6 genes para los dos indicadores. En ambos casos, el intervalo de valores que pueden tomar se ha establecido entre 1 y 100. Inicialmente se hicieron mayores, pero experimentalmente no se encontraron valores superiores, por lo que se consideró reducirlo al intervalo propuesto.

#### 3.2.3.2.- Cromosomas relacionados con las ventanas temporales.

Este es uno de los elementos más importantes e innovadores de éste trabajo, ya que en un sistema de “trading” tradicional se trabaja con ventanas estándar, en minutos: quince y treinta, y en horas: una y cuatro, y luego de semanas o meses. Las ventanas temporales definen el tamaño de la vela, y por tanto, los precios de apertura y cierre que formaran parte de la definición de la propia serie temporal.

En ésta tesis no se va a operar con una ventana temporal concreta, sino que dejaremos que sea el propio algoritmo el que nos indique el tamaño óptimo de las ventanas en las que debe de operar, tanto para el MACD, como para el estocástico. Esto supone una innovación con respecto a los métodos tradicionales, y también un cambio de paradigma, ya que hasta ahora lo que se intentaba era encontrar las mejores estrategias posibles dentro de un marco temporal fijo. Lo que se propone es que sea la propia estrategia la que elija la ventana temporal en la obtiene un mejor desempeño. En muchas ocasiones se eliminan excelentes estrategias, qué de haberse trabajado en una ventana temporal correcta hubieran producido beneficios. Por ejemplo, en la Figura 13 se puede ver el factor de beneficio de una estrategia escogida al azar, aplicada a distintos marcos temporales y en distintos periodos anuales.




Figura 13.- Factor de beneficio para la estrategia clásica del macd.

En la Tabla 9 se puede observar con más detalle los datos numéricos asociados a su realización. La operativa en la ventana de quince minutos genera pérdida, en comparación con el resto. Por otra parte, el número de operaciones referentes al periodo de cuatro horas, en media, no sobrepasa las treinta y siete operaciones. Esto hace que si la estrategia no tiene un factor de beneficio muy grande, al operar muy pocas veces, el rendimiento es bajo. En el mercado real, y de forma generalizada para todas las estrategias, escalas demasiado grandes son poco interesantes. Por ello, se ha limitado éste parámetro a ventanas inferiores a mil cuatrocientos cuarenta minutos.

	15 minutos	1 hora	4 horas
Factor de beneficio	0.906363636	1.134545455	1.528181818
Nº Operaciones	199	84	37
Rendimiento medio(\$)	-19.9	95.248	56.6

Tabla 9.- Rentabilidad media de la estrategia en el periodo 2001-2012.

En el experimento anterior se ha podido visualizar la relación existente entre el éxito de una estrategia y su aplicación sobre una escala temporal determinada. Para estudiar éste punto de una forma más detallada vamos a realizar un segundo experimento, en el que usaremos la misma estrategia pero con un conjunto de datos menores, en este caso la muestra de datos será de 21 semanas partiendo desde el 1 de enero de 2006, también para el mercado de divisas EUR/USD. Éste periodo ha sido seleccionado al azar.

En la Figura 14 se puede ver el número de operaciones y los beneficios. Igual que sucedía en el experimento 1, La misma estrategia aplicada en la ventana temporal de cuatro horas genera beneficios, mientras que la de 15 minutos y una hora genera pérdida.




Figura 14.- Numero de operaciones.

En la Figura 14 se ha incluido con el epígrafe de "total", el sumatorio del beneficio obtenido al operar las estrategias únicamente cuando su factor de beneficio es mayor de uno, siendo éste el mayor de todos los obtenidos. En la Tabla 10, podemos ver el detalle del factor de beneficio

para el conjunto de datos. Se ha resaltado de color azul las semanas donde ha sido mayor que uno.

Semana	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
15 min	0.4	0.5	0.6	0.6	0.8	0.5	0.5	0.6	0.8	0.9	1.2	1.2	1.6	1.9	1.8	1.6	1.5	1.7	1.7	1.7	0.9
1 Hora	3.9	3.7	0.9	0.6	0.9	0.8	0.9	0.8	0.4	0.5	0.6	0.9	1.8	1.1	0.8	0.7	0.6	0.8	0.8	0.6	0.4
4 Horas	3.2	2.4	5.0	5.0	4.0	5.0	5.0	5.0	4.0	3.0	4.0	2.1	1.4	3.2	3.0	3.0	4.3	5.4	5.4	5.9	5.9

Tabla 10.- Factor de beneficio semanal.

En resumen, las ventanas temporales en las que se aplica una estrategia son determinantes para el éxito de la misma. En ocasiones una misma estrategia en la misma ventana temporal puede pasar por fases de beneficio o pérdida. Una de las aportaciones de este trabajo es que sea el propio algoritmo evolutivo el que decida la escala temporal en la que debe operar la estrategia.

Por otra parte, para un mismo conjunto de datos, cuanto mayor sea la escala, menor será el tamaño de la serie temporal. Esto tiene como consecuencia que el número de operaciones que puede realizar el sistema disminuye. En la Figura 15 se puede ver el número de operaciones para periodos anuales entre 2001 y 2012, y se puede observar lo explicado anteriormente en cuanto al volumen de las operaciones. En la misma figura, también se puede ver como a partir del 2008 éste aumenta en un 30%.




Figura 15.- Número de operaciones para la estrategia por años.

En ésta tesis, la menor ventana de tiempo con la que se puede operar será la de un “tick”. Es decir, las escalas de los marcos temporales serán de un “tick”. Inicialmente, en los primeros experimentos, se utilizaron de otros tamaños, pero finalmente se adoptó ésta última opción. Esta elección se debe a la creencia de que la información va conformando el precio del activo, y el sistema de “trading” tiene que ser capaz de adaptar ésta lo antes posible para predecir su posible variación, y la velocidad con la que se va a producir. Por ejemplo, una persona que lee el periódico al levantarse, y a partir de aquí toma sus decisiones de inversión, sería alguien que trabaja en una ventana temporal de un día, otra que escucha los boletines informativos de la radio cada hora, utilizaría el marco temporal de una hora, mientras que uno que tuviera instalado un teletipo podría realizar la toma de decisiones conforme llega la noticia. Evidentemente, éste último tendría más información para saber lo ocurrido y sus tiempos de entrada y salida del mercado serían más precisos, algo que es fundamental.

En cualquier caso, trabajar en una escala o en otra no te garantiza una mayor ganancia, pero lo que sí está claro, es que en el análisis técnico el precio de cierre de los quince minutos se corresponde a la conformación del precio en éste intervalo, y por tanto, si al sistema de "trading" sólo le incorporas un dato, el de cierre de los quince minutos, tendrá más dificultad en saber lo que ha sucedido en ese periodo, que si tiene conocimiento minuto a minuto de los que pasó en ese periodo, por no decir si lo hace "tick" a "tick".

Al principio se pensó en establecer una restricción en cuanto a la relación de las ventanas de los indicadores, ya que teóricamente la ventana del MACD es la que marca la tendencia, y debería ser mayor que la del estocástico, pero finalmente se ha dejado que sea el propio algoritmo el que marque esta restricción si la considera necesaria.

Esto da lugar a dos cromosomas dentro del gen, uno para la escala de la serie temporal del MACD, y otro para el estocástico. Los valores serán enteros entre 1 y 1440. La restricción se ha establecido en función de un conjunto de experimentos que no mejoraban para escalas temporales mayores.

### 3.2.3.3.- Cromosomas relacionados con la operativa del mercado.

Como se ha explicado en el apartado 3.2.1, los parámetros relacionados con la operativa de mercado son tres: "stop-loss", take-profit y "trailing-stop". El valor que pueden tomar se corresponde con "pips", y está entre 5 y 300.

Por ejemplo, para una operación en EUR/USD, y con un apalancamiento de 1:100, cada "pip" equivaldría a una ganancia o pérdida de 10 dólares, por lote comprado. Esto supone que si se escoge un "stop-loss" de 15 "pips", la pérdida máxima que podríamos obtener equivaldría a 150 dólares. Igualmente si asignamos un take-profit de 50 "pips", esto equivaldría a una ganancia de 500 dólares. En este punto, hay que realizar una observación, que el "stop-loss" no es exacto, ya que hay ocasiones en las que se produce un salto y la pérdida puede ser mayor. Para ser más precisos el "stop-loss" es el precio al que nos gustaría cerrar la operación. Esto también ocurre en la entrada a los mercados, es posible que el precio de compra con el que se quiere entrar haya variado, y por eso en la propia orden aparece la desviación máxima que se estaría dispuesto a aceptar a partir de la propuesta de compra.

Finalmente se incorporaran tres cromosomas, cada uno correspondiente a un valor de mercado, al gen final.

### 3.2.3.4.- Cromosomas relacionados con la generación de señales.

#### 3.2.3.4.1 MACD

El cambio de tendencia entre las barras actual y la anterior pueden generar una señal de compra. El parámetro MACDpa y MACDpb tratan de localizar a partir de qué punto esa señal es más fiable. En Tabla 11 se pueden observar los dos cromosomas que se incorporan al gen y el intervalo de valores que puede tomar.

Parámetros	Valores
MACDpa	(0.100, -0.100)
MACDpb	(0.100, -0.100)

Tabla 11.- Parámetros MACD



### 3.2.3.4.2 Estocástico.

El estocástico tiene dos valores de referencia, a partir de los cuales se genera la zona de sobrecompra o sobreventa. Se denomina ESTpa para la referencia superior y ESTpb para la referencia inferior. En Tabla 12 se pueden observar los dos cromosomas que se incorporan al gen y el intervalo de valores que puede tomar.

Parámetros	Valores
ESTpa	(50-100)
ESTpb	(0-50).

Tabla 12.- Parámetros estocástico

### 3.2.4. Definición del gen.

Definitivamente el gen estará compuesto de 15 cromosomas. En la Tabla 13 podemos observar un ejemplo con los parámetros clásicos, y en la Tabla 14 los intervalos que pueden tomar.

MACD			ESTOCÁSTICO			ESCALAS TEMP.		MERCADO			Param. MACD		Param. ESTOCÁSTICO	
MACDa	MACDb	MACDc	ESTa	ESTb	ESTc	ESCT1	ESCT2	SL	TP	TS	MACDpa	MACDpb	ESTpa	ESTpb
12	26	9	14	3	3	60	15	15	50	3	2.3	1.7	80	20

Tabla 13.- Gen completo con la especificación de cada parámetro.

Cromosoma	Origen	Intervalos
MACDa	Primera media móvil del MACD	(1,100)
MACDb	Segunda media móvil del MACD	(1,100)
MACDc	Señal del MACD	(1,100)
ESTa	Primera media móvil del Estocástico.	(1,100)
ESTb	Segunda media móvil del Estocástico.	(1,25)
ESTc	Tercera media móvil del Estocástico.	(1,25)
ESCT1	Escala Temporal para el MACD	(1,1440)
ESCT2	Escala Temporal para el Estocástico	(1,1440)
SL	"stop-loss"	(6,300)
TP	"take-profit"	(6,300)
TS	"trailing-stop"	(5,100)
MACDpa	Referencia por encima del cero que permite que las señales puedan ser consideradas.	(0.100, -0.100)
MACDpb	Referencia por debajo del cero que permite que las señales puedan ser consideradas.	(0.100, -0.100)
ESTpa	Referencia por encima del cero que nos indica la zona de sobrecompra.	(50,100)
ESTpb	Referencia por debajo del cero que nos indica la zona de sobreventa.	(0,50)

Tabla 14. Valores de los parámetros del Gen.

Como podemos observar el espacio muestral es inmenso, del orden de  $1 e^{33}$ , esto permite que el uso de los algoritmos evolutivos esté justificado. Todos los cromosomas del gen estarán representados por una codificación entera, salvo los pertenecientes a MACDpa y MACDpb que tendrán una codificación real.



### 3.3.- Selección de los objetivos.

Antes de entrar en los objetivos se van a definir un conjunto de conceptos previos.

#### 3.3.1.- Conceptos relacionados

##### 3.3.1.1.- HPR. (“Holding Period Return”)

Este concepto se refiere al retorno obtenido durante un espacio de tiempo en el que se ha aplicado. Por ejemplo, 1.01 se refiere a una ganancia de un 1% y 0.99 se refiere a una pérdida de un 1%. Es un multiplicador que se utiliza habitualmente para comprobar cómo nos deja una pérdida o una ganancia.

##### 3.3.1.2.- TWR (“Terminal Wealth Relative”) o Riqueza relativa.

Es el valor que se obtiene a partir de la multiplicación de los HPR.

$$TWR = \prod_{i=1}^n HPR \quad (3.1)$$

Cuando se multiplican los HPRs se obtiene un valor que es indicativo de la media geométrica de la siguiente forma:

$$\text{Media Geométrica} = (TWR)^{1/N} \text{ donde N es el número de operaciones.} \quad (3.2)$$

Cuanto mayor sea el TWR, mayor será la media geométrica, y por tanto, el rendimiento del sistema.

##### 3.3.1.3.- Expectativa matemática.

Ésta es la cantidad que se espera ganar o perder en promedio en cada operación. Supongamos un sistema que tiene un porcentaje de aciertos del 95%, y que la ganancia promedio es de 100 euros, mientras que la pérdida promedio es de 2500 euros. La expectativa de este sistema es  $0.95 * 100 - 0.05 * 2500 = -30$ . Es curioso ver como un sistema en el que has acertado el 95 % de las veces y aun así, sus expectativas son negativas.

La expectativa es una condición necesaria pero no suficiente para que un sistema sea rentable, ya que ésta no tiene en cuenta el número de operaciones. Por ello es necesario además evaluar el TWR. Si un sistema tiene expectativas positivas y un TWR mayor que uno, entonces tenemos una estrategia rentable, en la cual siempre obtendremos beneficios positivos si invertimos la misma cantidad de capital o el TWR es positivo.

Para calcular la expectativa de un sistema a partir de su porcentaje de aciertos y del ratio ganancia/pérdida se utiliza la siguiente expresión.

$$\text{Expectativa Matemática} = (1+B) * P - 1 \quad (3.3)$$

donde

B= ratio ganancia/pérdida promedio.

P = Porcentaje de aciertos.

### 3.3.1.4.- La ecuación fundamental de “trading”

El objetivo fundamental de un sistema de “trading” es conseguir beneficios, para ello, en primer lugar éste debe tener una expectativa matemática positiva. Una vez que se ha conseguido esto, cuanto más opere éste más ganancias se pueden obtener. Además, hay algunos factores a considerar, como pueden ser el coste de la máxima pérdida o el número máximo de pérdidas consecutivas, ya que pueden hacer que un buen sistema elimine a un inversor del mercado en un momento dado. Todos estos objetivos se recogen en la denominada “ecuación fundamental del trading” [Cagigas 2006]:

$$TWR = [\text{med}^2 - \text{desv}^2]^{N/2} \quad (3.4)$$

donde

Med es la media aritmética en HPR

Desv es la desviación típica en forma de HPR.

N es el número de operaciones.

El objetivo es maximizar esta función agregada. La cual vamos a subdividir en subcomponentes para atacarlo como un problema multiobjetivo.

### 3.3.2.- Funciones objetivo

El objetivo principal de la presente tesis es proponer un método de trabajo que permita determinar los parámetros óptimos de configuración para los indicadores, las ventanas temporales y los parámetros relacionados con la operativa de mercado. La inclusión de estos indicadores ha sido necesaria para llevar a cabo una estrategia determinada, aunque no existe acoplamiento alguno entre el trabajo y la estrategia seleccionada.

Inicialmente se puede pensar que el único objetivo a optimizar para un sistema de “trading” es aquel que permita maximizar su beneficio, tal y como podemos observar en algunos trabajos como el de [Papadamou06]. En el enfoque que aquí se propone se consideran varios objetivos como ya se ha comentado más arriba.

El primero de ellos es maximizar el beneficio. Éste se ve afectado por las comisiones que cobran los bróker y también por los intereses relacionados con el capital. Aquí surge la paradoja de que en un sistema con expectativas positivas, cuanto más se opere más ganancias obtendrá, y por otra parte más comisión se debe abonar. Por tanto, se hace necesario entrar en el mercado con un margen suficiente, el control de éste es primordial para la obtención de beneficios. También hay que tener en cuenta que el capital con el que operamos es cedido por un tercero, el cual cobra unos intereses en función de la cantidad y del tiempo que dispongamos del mismo. Una operación que se encuentre demasiado tiempo abierta pagará muchos intereses, y puede llegar a comerse los beneficios. Como se puede deducir no es una tarea sencilla obtener beneficios. En algunos trabajos se recomienda minimizar el número de operaciones para evitar el pago de comisiones. Esto no tiene ningún sentido, puesto que si tu expectativa es positiva cuánto más se opere más ganancia se obtiene, y por otra parte,

también se recomienda conservar las operaciones en el tiempo, si éstas se mantienen, los intereses pueden ser tan altos que hagan que los beneficios se diluyan.

Determinar la cuantía de las comisiones es una labor harto complicada cuando no imposible debido a la variedad de operadores en el mercado con sus distintas tarifas y rangos de aplicación. En este trabajo únicamente se ha considerado el spread, que es la diferencia entre el precio de compra y el de venta de una divisa., y que toma un valor medio correspondiente a 0.0002 “pips” para el par EUR/USD. En cuanto a los intereses se han incluido en el beneficio final restándolo del mismo. Debido a la dinámica del sistema, muchas de las operaciones no tienen intereses por que se operan en el mismo día.

El segundo objetivo está relacionado con la minimización del riesgo y la búsqueda de soluciones robustas en el tiempo y con una desviación mínima. En nuestro sistema, éstas son continuamente evaluadas con los nuevos datos que se generan en el mercado. Esto hace que en cualquier momento una solución pueda ser mejorada por otra, generada por el propio sistema, o por una existente que se adecúe mejor al nuevo conjunto de datos. Si éstas cambian mucho significa que son poco robustas, que han funcionado bien en unas condiciones de mercado, pero que en cuanto que éste ha variado un poco ya no son válidas. En muchos casos estas soluciones son reemplazadas antes de iniciar cualquier operativa.

Otro problema asociado es el de la desviación, cuanto mayor sea ésta mayor es el riesgo de encadenar un conjunto de soluciones perdedoras que terminen por arruinar nuestras expectativas. Por tanto, buscamos sistemas en los que el cociente entre la media y la desviación (ratio de Sharpe simplificado) sea lo más elevado posible, minimizando este riesgo.

El tercer objetivo está relacionado con el rendimiento, es decir, encontrar soluciones que tengan una buena expectativa, pero que además generen muchas operaciones.

#### **3.3.2.1.- Función objetivo 1: maximizar la media aritmética (maximizar el retorno)**

El objetivo de la estrategia es generar señales de entrada y salida en el mercado. Una vez creadas, con una compra a corto o una compra a largo, éstas puede ser modificada en función de las propias condiciones del mercado. Es decir, la posición no es algo fijo como se recoge en muchos trabajos, más bien todo lo contrario, porque gran parte del beneficio se obtiene de éstas modificaciones posteriores. Las señales de salida generan el cierre de la operación. El periodo de tiempo entre la apertura y cierre de la operación generará una diferencia entre el precio de entrada y de salida y por tanto el beneficio obtenido en la operación. Este beneficio puede ser positivo o negativo, y en él se debe incluir tanto los intereses como las comisiones. Según lo anterior se puede realizar la siguiente definición.

- **RETORNO OBTENIDO DE LA ESTRATEGIA X PARA UNA OPERACIÓN  $O_x(a, b)$ :** Dada una estrategia de inversión, consistente en operar sobre un valor o índice, entre las señales de entrada y salida generadas por la misma y sobre un conjunto de parámetros fijados, en un intervalo determinado  $(a, b)$ , se denomina retorno obtenido de la posición, a la diferencia entre el precio de apertura y el de cierre, descontando las comisiones.

$$O_x = (\text{Precio}_{\text{apertura}} - \text{Precio}_{\text{cierre}} - (\text{Intereses})) \quad (3.5)$$

En este caso la ecuación (3.1) coincide con el concepto de HPR definido al principio del capítulo. La única diferencia está en que el  $\text{HPR}_x$  se define en porcentaje y se calcula de forma distinta en función de que se produzca una compra o una venta.

$$\text{HPR}_{x\text{compra}} = 1 + (C_f - C_o)/C_o; \quad \text{HPR}_{x\text{venta}} = 1 - (C_f - C_o)/C_o \quad (3.6)$$

$C_o$  es el precio al inicio de la operación más la comisión de la operación.  $C_f$  es el precio al final de la operación.

A continuación, en el algoritmo 3.1 se puede observar el código de la función que implementa el cálculo del  $\text{HPR}_x$ .

---

**Algoritmo 3.1: Cálculo del HPR**


---

```
public float evaluar(float precio){
/* La ganancia seria si apostamos un lote 100.000$ que con
apalancamiento seria * 1000$ podemos ganar 10$ por pips. */

precio = precio*100000;
precio = java.lang.Math.round(precio);
precio = precio/100000;

//operacion de compra
float Co,Cf,HPR,resultado;
if (tipo==1){

Co = precioEntrada;
Cf = precio;
resultado = (float) (Cf-Co)/Co;

//Operacion Venta
}else{
Co = precioEntrada;
Cf = precio;
resultado= (float) -(Cf-Co)/Co;
}
HPR = 1 + resultado;
return HPR;
}
```

---

En un intervalo de tiempo, se pueden abrir un conjunto de posiciones. Según lo anterior, se puede realizar la siguiente definición:

- RETORNO OBTENIDO DE LA ESTRATEGIA X EN EL INTERVALO  $[a, b]$  ( $B_x(a, b)$ ): Dada una estrategia de inversión, consistente en operar sobre un valor o índice, entre los instantes temporales  $a$  y  $b$ , según las señales sugeridas por la misma con un conjunto de parámetros fijados, se denomina retorno obtenido de la estrategia X en el intervalo  $[a, b]$  al sumatorio de los retornos individuales de las posiciones tomadas en dicho intervalo.

$$B_x(a, b) = \sum_{i=a}^b O_{xi} \quad (3.7)$$

Este concepto coincide con el comentado al principio del capítulo como TWR (“Terminal Wealth Relative”) o Riqueza relativa. Es el valor que se obtiene a partir de la multiplicación de los HPR. En la ecuación anterior el sumatorio se sustituye por un productorio debido a que los HPR están en porcentaje.

$$TWR = \prod_{i=a}^b HPR_i \quad (3.8)$$

Con este término podemos calcular la media geométrica, que es la que se utiliza para calcular la bonanza de un sistema en el que se reinvierten los beneficios. Cuanto mayor sea el TWR, mayor será la media geométrica y, por tanto, el rendimiento del sistema.

$$\text{Media Geométrica} = (TWR)^{1/N} \text{ donde } N \text{ es el número de operaciones.} \quad (3.9)$$

Para comparar dos estrategias simplemente tendríamos que calcular la media geométrica de ambas y saber cuál de ellas es mayor.

La media geométrica también se puede calcular en función de la media aritmética y la desviación estándar, a través de la denominada ecuación fundamental del “trading”, explicada al principio del capítulo.

$$\text{Media Geométrica} = \sqrt{\text{med}^2 - \text{des}^2} \quad (3.10)$$

Puesto que la media geométrica y el TWR se relacionan por la raíz N-ésima podemos estimar el TWR como:

$$TWR = [\text{med}^2 - \text{des}^2]^{N/2} \quad (3.11)$$

Por tanto, si la media aritmética es mayor de uno, esto implica que su HPR también lo será, y si su desviación es tal que el término dentro del corchete es mayor que uno, entonces cuantas más operaciones realicemos mayor será el retorno.

**-Objetivo 1: Maximizar la media aritmética, maximiza el TWR.**

### 3.3.3.2.- Función objetivo 2: Minimizar el riesgo de la estrategia.

Un inversor puede contar con una excelente estrategia de “trading” y terminar perdiendo capital si no emplea una gestión de riesgo adecuada. Básicamente, la gestión de riesgo es una combinación de múltiples parámetros relacionados entre sí, entre los que destacamos los siguientes:

- Contener el número máximo de pérdidas consecutivas (“drawdown”)
- Controlar la dispersión de las operaciones respecto del promedio. (Desviación típica)
- Limitar la cantidad de capital invertido.
- Determinar los límites en cuanto a pérdidas (“stop-loss”) y ganancias (“take-profit”).

La ecuación para determinar la pérdida total en función del número de errores de inversión viene determinada por la siguiente ecuación (3.12):

$$n = \frac{1}{\ln(1 - p)} \quad (3.12)$$

Donde  $n$  es el número de errores y  $p$  el porcentaje de pérdida.

En la Tabla 15 podemos observar cómo se comporta el riesgo en función de la máxima pérdida esperada. En ella se puede ver como si se invierte un 10 % del total del capital disponible, el número máximo de pérdidas consecutivas se reduce drásticamente a 9. Es decir, con una racha de 9 pérdidas seguidas se dilapida todo el capital. Esto hace que sea necesario limitar el capital con el que se opera. La ecuación para el caso de trabajar sólo con el 50% del capital sería la siguiente:

$$n = \frac{\ln(\frac{1}{2})}{\ln(1 - p)} \quad (3.13)$$

En el caso de operar con el 25% del capital total y si se decide trabajar con valores de “stop-loss” que limiten nuestra pérdida a un 3%, se podría aguantar más de veinticinco operaciones fallidas de forma continuada.

Operaciones Fallidas	25 % Capital	50 % Capital	100 % Capital
1	138	69	99
2	69	34	49
3	46	23	33
4	34	17	24
5	27	14	19
6	22	11	16
7	19	10	14
8	17	8	12
9	15	7	11
10	13	7	9
11	12	6	9
12	11	5	8
13	10	5	7
14	9	5	7
15	9	4	6
16	8	4	6
17	7	4	5
18	7	3	5
19	7	3	5
20	6	3	4
21	6	3	4
22	6	3	4
23	5	3	4
24	5	3	4
25	5	2	3

Tabla 15.- Pérdida de capital en función del número de operaciones fallidas.

Es evidente que no se puede controlar el número de operaciones fallidas que puede tener un sistema, pero sí se puede limitar los parámetros de ganancia-pérdida en función del capital que se desea arriesgar.

Un buen sistema debe trabajar con operaciones que tengan una dispersión pequeña respecto al promedio. Es decir, se debe controlar que la desviación estándar sea lo más pequeña posible. De esta forma, no será necesario tener unos "stop-loss" y "take-profit" demasiado grandes. Además, si retornamos al concepto inicial de media geométrica, vemos que la minimización de ésta hace que se maximice la media geométrica, y por tanto, el retorno de la inversión.

Otro factor de riesgo a controlar es la permanencia de las operaciones en el mercado, y el interés que generan. Por tanto, es importante fijar un take-profit que permitan recoger ganancias y no tener una posición abierta en un mercado lateral, que lo único que hace es consumir recursos, y generar pérdidas.

Cuando se habla del retorno de la inversión, es referido a un porcentaje de la inversión inicial, y no a una cantidad determinada. En posteriores capítulos se hablará de la fracción óptima de capital a arriesgar para maximizar los beneficios, aunque éste capital óptimo estará limitado por el riesgo máximo que se quiera asumir. Es decir, si el riesgo limita el capital máximo disponible a un veinticinco por ciento y la fracción óptima nos indica que el capital óptimo a invertir es de un treinta por ciento, éste segundo se verá limitado por el primero, y únicamente se invertirá el veinticinco por ciento del capital total como máximo para limitar el riesgo.

En resumen, una desviación mínima en promedio hace que las operaciones trabajen en una franja pequeña, limitando el tiempo de la operativa y del "drawdown". Esto permite maximizar el capital disponible para la operativa y minimizar el riesgo.

**-Objetivo 2: Minimización de la desviación estándar, maximiza el TWR.**

#### **3.3.3.4.- Funciones objetivo 3: Maximizar el número de operaciones**

El inversor siempre trata de reducir el riesgo global de su inversión diversificando su cartera. Ésta acción lo que busca es añadir diversidad para encontrar sinergias que consigan acelerar el proceso de crecimiento del capital. Cuando se opera con un sistema que tiene una expectativa positiva, conseguir más operaciones en el mismo periodo de tiempo contribuye a maximizar este incremento, y por ende su diversificación.

Una cartera diversificada no es nada más que un conjunto de valores que operando en conjunto obtienen una expectativa positiva. El tema de que los valores no estén correlacionados es pura ficción, puesto que cuando el mercado tiene un mal o buen día todos los valores se correlacionan, y las pérdidas o ganancias son generalizadas.

En el sistema desarrollado en este trabajo la cartera de valores está conformada por todas las posibles soluciones del frente de Pareto al completo. En este caso, cada una de ellas busca su propia diversificación, maximizando el número de operaciones que se realizan. Esto contribuye a una diversificación de todo el sistema, o cartera de valores. Aquí hay que tener en cuenta, que una empresa tiene todo su capital líquido en divisas para poder comprar y vender productos constantemente y, por tanto, la diversificación sólo se puede producir sobre la propia divisa.

Aunque el sistema trabaja siempre con el mismo activo, las soluciones son completamente distintas. Esto permite que dentro del mismo marco temporal de operaciones se produzcan órdenes de compra y venta.

Otro factor a tener en cuenta es el del rendimiento de la inversión. Una estrategia que tiene una expectativa muy positiva, pero sólo opera una vez, ofrece un peor rendimiento que una estrategia que tiene una expectativa positiva y opera muchas veces. Un inversor busca siempre obtener el mayor rendimiento posible a su inversión y para ello es necesario incrementar el número de operaciones.

**-Objetivo 3: maximizar el número de operaciones, maximiza la diversificación y el rendimiento.**

### 3.4.- Análisis del conjunto de datos de la experimentación.

Para éste estudio se ha utilizado la serie de datos del par EUR/USD del mercado de divisas. En la Figura 16 se puede observar en una ventana temporal mensual desde el 30 de septiembre de 1999 hasta el 30 de septiembre de 2009. Para realizar un análisis inicial se ha dividido en cinco subintervalos: (30/09/1999–30/09/2001), (30/09/2001–30/09/2003), (30/09/2003–30/09/2005), (30/09/2005–30/09/2007), (30/09/2007–30/09/2009).




Figura 16.- Conjunto de datos par EUR/USD desde 30/09/1999 al 30/09/2009

Estos conjuntos han sido escogidos por que representan un periodo lo suficientemente amplio y además constituyen diferentes tendencias del mercado, las cuales han sido resumidas en la Tabla 18.

Periodo	Tendencia
1999-2001	Dientes de sierra no muy pronunciados
2001-2003	Tendencia Alcista
2003-2005	Tendencia Alcista hasta la mitad y bajista hasta el final.



2005-2007	Tendencia Alcista.
2007-2009	Dientes de sierra pronunciados.

Tabla 16.- Resumen de tendencias para el conjunto de datos.

Dentro de éstos subconjuntos se han escogido a su vez tres conjuntos de datos con los que se realizarán todos los experimentos, que son los que aparecen en la Tabla 17.

Conjunto	Intervalo	Tamaño
1	29 de marzo de 2004 al 2 de julio de 2004	800.000 datos
2	27 de marzo de 2006 al 30 de junio de 2006	660.000 datos
3	31 de marzo de 2008 al 30 de junio de 2008	675.000 datos

Tabla 17.- Resumen de tendencias para el conjunto de datos.

En la Figura 17 se puede observar el primer conjunto de datos, el cual se caracteriza por pertenecer a un mercado lateral.



Figura 17.- 1 de abril de 2004 a 30 de junio de 2004.

En la Figura 18 se puede ver el segundo conjunto de datos, el cual se caracteriza por su clara tendencia alcista.



Figura 18.- 27 de marzo de 2006 al 30 de junio de 2006

En la Figura 19 se puede visualizar el tercer conjunto de datos, el cual se caracteriza por su un mercado sin tendencia, pero con fuertes caídas y subidas, a diferencia del primero.



Figura 19.- 31 de marzo de 2008 al 30 de junio de 2008

Los datos utilizados han sido obtenidos de la página web <http://ratedata.gaincapital.com/>. Éstos tienen un formato de BID/ASK y son “tick” a “tick”.

### 3.5.- Sistemas de negociación de alta frecuencia

El sistema que se ha desarrollado dentro de ésta tesis se encuentra entre los denominados de alta frecuencia. La negociación de alta frecuencia, también conocida en el ámbito financiero por su nombre en inglés “high-frequency trading” o por sus siglas HFT, se caracterizan por utilizar de forma intensiva algoritmos y herramientas tecnológicas que analizan los datos del mercado para implementar estrategias de negociación. Cada posición de inversión se mantiene solo durante muy breves períodos de tiempo, para rápidamente ejecutar la posición y comprar o vender, según el caso, el activo de que se trate. Esto se realiza decenas de miles de veces al día, y los períodos de tiempo durante los que se mantienen las posiciones pueden ser de solo fracciones de segundo.

Uno de los primeros experimentos que se realizó en éste trabajo se hizo para analizar los fundamentos de estos tipos de sistemas. Para ello se utilizaron los indicadores MACD y estocástico, los cuales han sido explicados en la sección de indicadores técnicos (ver sección 1.4). La estrategia utilizada en la operativa ha sido la misma del apartado 3.2.2. (Generación interna de señales por parte de los indicadores). Los indicadores trabajaron en ventanas temporales fijas, más concretamente de 5, 15, 30, 60, 240, 1440 minutos. Cuando se genera una señal de operación, se evalúa la ganancia obtenida en un lapso de tiempo determinado. Este intervalo se ha denominado intervalo de confiabilidad. Aquí se analizan los correspondientes a 5, 15, 30, 60, 240 y 1440 minutos. La ganancia obtenida es calculada en número de “pips”.

Este experimento tiene algunas diferencias con respecto al funcionamiento final de la aplicación. Las ventanas temporales han sido previamente fijadas, al igual que el cierre de las operaciones. En ambos casos, en la herramienta final son escogidas por el propio algoritmo. El

objetivo es ensayar el marco óptimo para la realización de la operativa sin entrar en detalles de optimización para escalas temporales o condiciones de cierre.

Para este estudio se ha utilizado la serie de datos del par EUR/USD del mercado de divisas, desde el 30 de septiembre de 1999 hasta el 30 de septiembre de 2009, para intervalos de precios de un minuto. Para la realización del trabajo, éste conjunto de datos ha sido dividido en cinco subintervalos: A (30/09/1999 – 30/09/2001), B (30/09/2001 – 30/09/2003), C (30/09/2003 – 30/09/2005), D (30/09/2005 – 30/09/2007), E (30/09/2007 – 30/09/2009). Para cada serie de datos, se generan un conjunto de señales, las cuales son evaluadas para obtener las ecuaciones 3.14 y 3.15:

$$\text{El promedio de la ganancia } \frac{\sum_{i=0}^n G_i}{n} \quad (3.14)$$

$$\text{El ratio de Sharpe simplificado } \frac{\frac{\sum_{i=0}^n G_i}{n}}{\sigma} \quad (3.15)$$

Los valores por defecto de todos los parámetros son 0, y las ventanas temporales e intervalos de confiabilidad son de 5, 15, 30, 60, 240 y 1440.

En la Tabla 18 se tiene el resultado para el ratio de Sharpe simplificado, y se puede observar cómo el mayor de ellos se alcanza cuando el tamaño de la ventana temporal coincide con el intervalo de confiabilidad. Este resultado es muy interesante, puesto que nos indica que la ventana temporal principal para la toma de decisiones debe coincidir con el marco temporal en el que queremos invertir, ya que es el que ofrece un menor riesgo.

Ratio de Sharpe simplificado de los mejores valores					
	A	B	C	D	E
5	0.5272	0.5373	0.5079	0.5140	0.6074
15	0.7276	0.7110	0.6735	0.6662	0.7182
30	0.8263	0.7766	0.6961	0.7162	0.7717
60	0.9640	0.9282	0.7628	0.8152	0.8765
240	1.0353	0.9355	0.8908	0.8515	1.2007
1440	1.0486	1.1572	0.7347	0.8761	1.2268

Tabla 18.- Resumen de los mejores ratios por ventana e intervalo de confiabilidad

También se puede ver que cuanto mayor es la ventana, mayor es el ratio. Esto es una cuestión que tiene cierta lógica, ya que se generan menos operaciones y, por tanto, la posibilidad de que estas sean de pérdida es menor. En cualquier caso, una primera conclusión podría ser que las operativas a largo plazo tienen un menor riesgo que las que son a corto plazo.

En las siguientes tablas (19-22), se recogen el número de operaciones y los distintos beneficios con spread y sin spread.

Número de Operaciones						
	A	B	C	D	E	Media
5	2266	2124	2232	1795	2742	2232
15	1027	942	1026	818	1166	996

30	652	540	582	524	609	581
60	341	305	307	269	341	313
240	85	96	86	86	90	89
1440	14	17	16	13	17	15

Tabla 19.- Número de operaciones

Beneficio en "pips" sin spread							
	A	B	C	D	E	Promedio	Desviación
5	1264	874	982	555	1714	1078	437
15	1136	810	895	552	1503	979	360
30	1086	641	796	529	1119	834	263
60	866	546	662	471	784	666	163
240	411	272	304	240	407	327	78
1440	111	127	61	84	138	104	32

Tabla 20.- Beneficio sin spread

Tabla 21.- Estimación de ganancias con spread.

Beneficio en "pips" con spread (0.0002)							
	A	B	C	D	E	Promedio	Desviación
5	810	450	536	196	1166	631	371
15	931	621	690	388	1270	780	335
30	956	533	680	424	997	718	253
60	797	485	601	418	716	603	157
240	394	253	287	223	389	309	78
1440	108	123	58	81	135	101	32

Tabla 22.- Beneficios en "pips" con spread.

Se puede observar que los mayores beneficios se obtienen para escalas temporales inferiores, es decir, para las operativas de cinco y quince minutos. Recordar que este experimento se realizó para datos de un minuto, y los experimentos posteriores se generarán "tick" a "tick". Por otra parte, el ratio de Sharpe simplificado disminuye, pero mantiene unos valores lo suficientemente buenos para tener una operativa con un riesgo contenido. Una vez que la estrategia tiene una esperanza matemática positiva, se busca que ésta genere el máximo número de operaciones, para maximizar el rendimiento. Otro factor fundamental que se puede ver en éste experimento, es que para unos intervalos de desviación aceptables, aumentar ésta aumenta el número de operaciones, y por tanto, dispara el beneficio.

En resumen, las claves de estos sistemas consisten en minimizar las escalas temporales y maximizar la desviación estándar, en un intervalo seguro, que maximice el ratio de Sharpe. De esta forma, se disparan el número de operaciones, lo que conlleva una mejora muy importante del rendimiento. Evidentemente éste tipo de sistemas abren una brecha en el mercado tradicional, donde la operativa se producía a más largo plazo, con un número de transacciones muy pequeño. Otra consecuencia es que sólo sistemas informatizados pueden llevar a cabo éste tipo de operativa.

Los objetivos propuestos en ésta tesis, explicados en el apartado anterior, son fruto de ésta investigación inicial y se enmarcan en la línea de estos tipos de sistemas de alta frecuencia.

### 3.6.- Conclusiones.

En éste capítulo se ha realizado una presentación de la arquitectura de la aplicación y los módulos que la componen, haciendo especial hincapié en explicar la funcionalidad de los mismos. Esto nos permite centrarnos en los conceptos fundamentales sin necesidad de entrar en la complejidad de la interacción entre los elementos atómicos.

Posteriormente, se han explicado en profundidad los distintos parámetros que conforman el gen, así como sus restricciones operacionales. Éstas han sido propuestas fruto de una intensa investigación empírica y miles de experimentos realizados. En éste mismo apartado se ha tratado con especial detalle la importancia de los marcos temporales para la toma de decisiones, y la innovación que supone que sea el propio algoritmo el que decida el intervalo sobre el cual va a trabajar.

A continuación se han descrito los objetivos planteados para el problema de optimización multiobjetivo. Estos han sido seleccionados por su importancia en la operativa en los mercados.

En el siguiente apartado se han analizado los conjuntos de datos que se utilizarán en los experimentos posteriores.

Finalmente, han sido descritos los sistemas multifrecuencia, dentro de los cuales se encuentra el desarrollado en éste trabajo, junto con un experimento que fundamenta teóricamente la elección de los objetivos seleccionados en los apartados anteriores.

## **4. Implementación del algoritmo genético para la gestión de estrategias de “trading”**

---

### **4.1 Introducción**

### **4.2 La librería JMetal**

### **4.3 Selección del algoritmo multiobjetivo**

### **4.4 Análisis de los parámetros del Algoritmo SPEA-II**

### **4.5 Conclusiones**

---

En este capítulo se exponen los resultados experimentales realizados para la selección del algoritmo evolutivo que será posteriormente utilizado. Para ello, se ha llevado a cabo un conjunto de experimentos, en los que se evalúan distintos algoritmos genéticos para distintos conjuntos de datos.

A continuación, se han realizado estudios para determinar los mejores operadores y sus ajustes correspondientes. Entre estos se incluyen los siguientes: operador de inicialización, selección, cruce, mutación y tamaño de la población.

## 4.1 Introducción

Los resultados presentados en éste capítulo son el fruto de una línea de investigación que se ha ido desarrollando en los últimos cinco años. En todo éste camino recorrido se han probado intensamente todos los algoritmos aquí presentados, cada uno de ellos con distintas variantes y ajustes.

Para ello ha sido necesario construir un software específico de simulaciones. Éste permite en un entorno en tiempo real simular el funcionamiento de la aplicación de “trading” desarrollada en éste trabajo. La complejidad de éstas maquinas es grande y ha ido sufriendo constantes cambios para acometer las distintas dinámicas desarrolladas en esta tesis. El principal de los ajustes ha sido la variación de los periodos temporales utilizados en la extracción de la información, de tal forma, que cada vez fuera más eficiente. Inicialmente se comenzó con un periodo de un día, después de una hora, posteriormente con 15 minutos, más tarde con un minuto, y finalmente “tick” a “tick”. Los resultados obtenidos en cada marco temporal han ido mejorando a los anteriores, y esto ha supuesto gran satisfacción, pero por otra parte, también muchísimo trabajo, ya que los experimentos han tenido que ser repetidos constantemente. Además, todos los componentes han ido evolucionando en el tiempo: la estrategia de “trading”, los indicadores y sus parámetros, los operadores en tiempo real, los conjuntos de datos, etc. Por tanto, este documento es la recopilación de todas estas experiencias y conocimientos.

Para la realización de las simulaciones se ha utilizado la librería JMetal que se expone en el siguiente apartado.

## 4.2 La librería JMetal

La librería de componentes de algoritmos evolutivos JMetal es un proyecto Open source desarrollado por Antonio J. Nebro, Juan J. Durillo [Durillo09], [Durillo10]. Esta librería está desarrollada en lenguaje JAVA, y su descarga y uso es gratuito bajo las condiciones reflejadas en la licencia que consta en su página web <http://jmetal.sourceforge.net/>

Se trata de una librería muy completa y compleja que permite utilizar diferentes tipos de codificaciones: binaria, gray, real, arbórea y listas. También incorpora diferentes tipos de operadores adaptados a cada codificación, así como la posibilidad de derivar nuevos tipos de codificaciones y operadores a partir de la librería de clases original.

Las opciones y características más destacadas son las siguientes:

- Algoritmos multi-objetivo: NSGA-II (variantes: ssNSGAI, NSGAIadaptive, NSGAIrandom), SPEA2, PAES, PESA-II, OMOPSO, MOCeII, AbYSS, MOEA/D, Densea, CellDE, GDE3, FastPGA, IBEA, SMPSO, SMPSOhv, SMS-EMOA, dMOPSO
- Algoritmos de un único objetivo: algoritmos evolutivos (variantes: generacional, steady-state, celular síncrono, celular asíncrono), estrategia evolutiva (variantes: elitismo or mu+lambda, no-elitista or mu, lambda), PSO, DE, CMA-ES
- Algoritmos paralelos: pNSGAI, pSMPSO, pMOEAD, pgGA
- Problemas incluidos: familias de problemas: ZDT, DTLZ, WFG, CEC2009, LZ09
- Problemas clásicos: Kursawe, Fonseca, Schaffer



- Problemas con restricciones: Srinivas, Tanaka, Osyczka2, Constr\_Ex, Golinski, Water
- Problemas combinatorios: multi-objective TSP, multi-objective QAP
- Indicadores de calidad: hipervolumen, spread, distancia generacional, distancia generacional inversa, additive epsilon, R2\*, WFG hipervolumen
- Codificaciones: binaria, real, codificación binaria real, integer, permutación, codificación mixta (real+binario, int+real).

De entre todas ellas, se destacan las empleadas en el desarrollo del presente trabajo:

**Algoritmos multi-objetivo:** NSGA-II, SPEA2, PAES, PESA-II, OMOPSO, MoCell

**Operadores de selección:** La librería contiene distintos operadores de selección: torneo, PESA2Selection, aleatoria, Selección por Ranking y Crowding. Además se han añadido otros como son los siguientes: por ruleta, por rango y por muestreo determinístico.

**Operadores de cruce:** La librería contiene los siguientes operadores de cruce: HUXCrossover, PMXCrossover, SBXCrossover, SinglePointCrossover, TwoPointsCrossover. En este caso sólo se han utilizado PMXCrossover. SBXCrossover.

**Operadores de mutación:** La librería incorpora los siguientes operadores de mutación: BitFlip, No Uniforme, Polinomial, Swap y Uniforme. Para éste trabajo sólo se ha utilizado la mutación polinomial.

**Codificación de las variables de diseño:** Dados los parámetros expuestos en el capítulo anterior la codificación empleada será una parte real, y otra entera.

### 4.3 Selección del algoritmo multiobjetivo

Los algoritmos multi-objetivo seleccionados para el estudio inicial han sido los siguientes: NSGA-II, SPEA-II, PAES, PESA-II y MoCell. Todos ellos son referencias fundamentales en la bibliografía del área, y se ajustan bien al tipo de problema que se quiere resolver. Todos ellos han sido explicados en el capítulo dos de forma detallada.

#### 4.3.1.- Evaluación de los resultados

Los algoritmos evolutivos son técnicas no deterministas pertenecientes al campo de las metaheurísticas. Esto implica que dos ejecuciones del mismo algoritmo sobre un problema dado no tienen por qué encontrar la misma solución. Esto supone un problema a la hora de evaluar los resultados y su posterior comparación. Existen algunos trabajos teóricos que abordan este problema [Graham69], [Karp77]; pero dada su dificultad, normalmente se utilizan comparaciones empíricas. Los algoritmos se contrastan en función de la calidad de las soluciones obtenidas y del esfuerzo computacional empleado en encontrarlas. Este esfuerzo se calcula en términos del número de evaluaciones de la función de aptitud empleado durante la búsqueda [Michalewicz00].

Las métricas empleadas para la evaluación de los algoritmos multiobjetivo se basan en dos aspectos fundamentalmente: 1.- Minimización de la distancia del frente de Pareto obtenido con respecto al óptimo. 2.- Maximización de la extensión de las soluciones sobre el frente, de forma que la distribución sea lo más uniforme posible. Por tanto, las métricas usadas en el

campo se pueden agrupar entre aquéllas que evalúan la cercanía a los frentes exactos, y las que miden la diversidad de las soluciones no dominadas obtenidas. Normalmente, antes de aplicar algunas de las métricas, es conveniente normalizar los valores sobre los que se aplican para obtener resultados fiables. Tal y como se propone en [Deb01b] se aplica la normalización con respecto al frente óptimo, si se conoce, o con respecto a la mejor y peor solución de nuestro frente en el caso de que no se conociera el óptimo.

Una vez aplicadas estas métricas, y para poder realizar las comparaciones sobre los resultados obtenidos, se utilizan funciones estadísticas. Las más habituales son: la media de los valores obtenidos, la mediana, o la mejor y peor solución encontrada. Pero estos valores no son significativos y pueden llevar a interpretaciones erróneas. Por tanto, se debe recurrir a estudios con significancia estadística, como t-test o análisis de varianza para distribuciones normales o el test de Kruskal-Wallis para aquellas que no lo son. Éstos permiten determinar si los resultados obtenidos son significativos o si, por el contrario, son debidos a errores en el muestreo realizado.

Para cada experimento se han realizado cien ejecuciones independientes del algoritmo sobre el problema dado. Una vez obtenidos los resultados de las ejecuciones, se les aplica un test de Kolmogorov-Smirnov con el fin de comprobar si los valores de los resultados siguen una distribución normal (gaussiana) o no. Si la distribución es normal, se realiza un test de ANOVA, mientras que si no lo es, el test que se aplica es el de Kruskal-Wallis. En los test realizados el nivel de confianza alcanzado es del 95% (nivel de significancia del 5% o p-valor por debajo de 0.05). Esto significa que se puede asegurar que las diferencias en los resultados son significativas con una probabilidad del 95 %.

En éste trabajo se utilizarán las siguientes métricas de rendimiento para evaluar los algoritmos propuestos: **Métrica de conteo exitoso**, **Dispersión Generalizada** [Zhou06], **Distancia Generacional Inversa** [Veldhuizen98b] e **Hipervolumen** [Zitzler02]. En los siguientes apartados se explican brevemente cada una de ellas.

**Métrica de conteo exitoso – MCE.** Consiste en determinar aquellos puntos del frente de Pareto generado ( $X_g$ ) que pertenecen al frente de Pareto verdadero ( $X_v$ ), y contarlos. Se define como:

$$MCE(X_v; X_g) = |\{x \in X_g \mid x \in X_v \mid \exists x' \in X_v \ f(x') \leq f(x)\}| \quad (4.1)$$

Un resultado de 0 indica que ambos frentes son totalmente diferentes; cualquier otro valor lejano a 0 indica que más puntos de  $X_g$  pertenecen a  $X_v$ ; por ello es deseable obtener valores altos. Esta métrica no mide la extensión de  $X_g$  sobre el frente verdadero  $X_v$ .

**Distancia Generacional Inversa – DGI.** Consiste en determinar para cada punto del frente de Pareto el punto de la solución que le es más cercano y sumar estas distancias para obtener en promedio, cómo de lejos está el frente de Pareto verdadero, del frente de Pareto generado. Se define como:

$$DGI = \frac{\sqrt{\sum_{i=1}^N d_i^2}}{n} \quad (4.3)$$

donde  $n$  es el número de vectores en el conjunto de soluciones no dominadas del frente generado, y  $d_i$  es la distancia Euclídea (medida en el espacio objetivo) entre cada una de estas soluciones y el miembro más cercano del conjunto óptimo de Pareto. Un resultado de 0 indica que ambos frentes son iguales; cualquier otro valor indica una divergencia entre ambos frentes; por ello es deseable obtener valores bajos de DGI.

**Dispersión Generalizada - DG.** La métrica de dispersión [Zhou06], es una medida de diversidad que cuantifica la magnitud que alcanza la dispersión entre las soluciones obtenidas. Esta métrica se define como:

$$DG = \frac{d_f + d_l + \sum_{i=1}^{N-1} |d_i - \bar{d}|}{d_f + d_l + (N-1) \bar{d}} \quad (4.4)$$

donde  $d_i$  es la distancia Euclídea entre dos soluciones consecutivas,  $\bar{d}$  es la media de estas distancias, y  $d_f$  y  $d_l$  son las distancias Euclídeas a las soluciones extremas (límite) del frente exacto de Pareto en el espacio objetivo. Esta medida toma el valor cero para una distribución ideal, remarcando una dispersión perfecta de las soluciones del frente de Pareto.

**Hipervolumen – HV.** Esta métrica calcula el volumen (en el espacio de objetivos) cubierto por miembros del un conjunto dado,  $Q$ , de soluciones no dominadas para problemas donde todos los objetivos han de ser minimizados. Matemáticamente, para cada  $i \in Q$  se construye un hipercubo  $v_i$  con un punto de referencia  $W$  y la solución  $i$  que definen la diagonal del mismo.

El punto  $W$  se puede obtener simplemente con los peores valores de las funciones objetivo. Entonces, la unión de todos los hipercubos es lo que define el hipervolumen (HV):

$$HV = \text{volumen} \left( \bigcup_{i=1}^Q v_i \right) \quad (4.5)$$

Los algoritmos que alcanzan mayores valores para HV son mejores. Como ocurría con las dos métricas anteriores, es necesario normalizar las soluciones no dominadas puesto que HV depende del escalado de los valores de la función objetivo.

#### 4.3.2.- Aproximación del frente de Pareto óptimo

Para la obtención de una aproximación al frente de Pareto óptimo, se ha llevado a cabo el siguiente procedimiento metodológico:

- i. Cada algoritmo será procesado cien veces para cada conjunto de datos.
- ii. Sobre el total de datos, se realizarán veinticinco mil evaluaciones cada once mil quinientos datos. Es decir, que si el conjunto uno tiene ochocientos mil datos, se obtendrán sesenta y nueve subconjuntos diferentes sobre los que se realizarán veinticinco mil evaluaciones para cada uno. Esto hace que en cada intervalo se

obtingan un conjunto de soluciones no dominadas, formadas por las no dominadas anteriores, más las obtenidas por el algoritmo. Este conjunto será sometido a un test de dominancia, para el conjunto actual de datos. Los individuos GANADORES serán los que operen en el siguiente intervalo. Este proceso continúa hasta que se evalúa el total de datos. Finalizado éste paso se obtiene un conjunto de soluciones cuyo estado sigue siendo activo, ya que no se encontró ninguna otra solución que la dominara. Éstas serán las utilizadas en el siguiente punto.

- iii. Se obtuvo para cada algoritmo un conjunto de soluciones no dominadas,  $P_1, P_2, \dots, P_N$ .
- iv. Se creó para cada algoritmo una superpoblación,  $P_T$ , donde  $P_T = \bigcup_{i=1}^N P_i$ .
- v. De cada superpoblación se extrajeron las soluciones no-dominadas, formando así el frente de Pareto de cada algoritmo como sigue:

$Y_{NSGAII}$  (frente Pareto con los procesamientos del algoritmo NSGA-II)

$Y_{SPEAII}$  (frente Pareto con los procesamientos del algoritmo SPEA-II)

$Y_{PAES}$  (frente Pareto con los procesamientos del algoritmo PAES)

$Y_{MoCell}$  (frente Pareto con los procesamientos del algoritmo MoCell)

$Y_{PESAI}$  (frente Pareto con los procesamientos del algoritmo PESA-II)

- vi. Se obtuvo el conjunto de soluciones encontradas como sigue

$$Y = Y_{NSGAII} \cup Y_{SPEAII} \cup Y_{PAES} \cup Y_{MoCell} \cup Y_{MoCell} \cup Y_{PESAI}$$

- vii. Del conjunto  $Y$  se obtienen las soluciones no dominadas, y así se forma una aproximación del Frente Pareto Optimo  $Y_{Optimo}$ .

#### 4.3.3.- Selección del algoritmo evolutivo para el problema propuesto

En este apartado se van a realizar una batería de experimentos, sobre los conjuntos de datos explicados en el capítulo anterior, para determinar el algoritmo evolutivo que consiga mejores soluciones para el problema propuesto.

La configuración utilizada para cada uno de los algoritmos se puede ver en la Tabla 23. Se han tomado los valores estándar recomendados por la propia librería, ya que se ha observado que generan buenos resultados.

Configuración del algoritmo evolutivo.
Tamaño de la población: $\mu = 100$ individuos.
Operador de inicialización: aleatorio.
Operador de selección: selección por torneo.
Operadores de cruce: Operador cruce SBX. Probabilidad de cruce de 0.9.
Operador de mutación: Mutación polinomial con probabilidad 0.07.
Manejo de las restricciones: No existen.
Tamaños de los ficheros externos SPEA-II y MOCell: 100 individuos.

Tabla 23.- Configuración del algoritmo evolutivo.

Los experimentos realizados sobre cada conjunto se engloban en dos enfoques distintos, uno a nivel local, con el estudio de los resultados obtenidos de la aplicación de las métricas sobre las soluciones no dominadas del último intervalo de cada conjunto, y otro a nivel global, con la observación del desempeño del algoritmo para el total del problema propuesto. Cuando se evalúa el conjunto de datos completo, se hace sobre distintos intervalos, cada uno de ellos supone una foto fija del estado del sistema en ese instante, por ejemplo, para el primer conjunto de datos hay un total de ochenta y cinco intervalos, se podría haber trabajado sobre cualquiera de ellos, aunque siempre sobre el mismo para poder compararlos. En éste trabajo se ha seleccionado el último. Como se verá en los resultados obtenidos, esta doble perspectiva permite una mejor toma de decisiones con respecto a la selección última del algoritmo.

Los resultados respecto de las métricas empleadas, incluyen la mediana,  $\bar{x}$ , y el rango intercuartílico, IQR, como medidas de localización y dispersión estadística, respectivamente. El mejor resultado se ha resaltado en negrita. Cada experimento se ha ejecutado quince veces de forma independiente. Posteriormente, se ha realizado un análisis estadístico de los resultados consistente en un análisis de Kolmogorov-Smirnov para comprobar si los valores de los resultados siguen una distribución normal o no. Si lo siguen, se ha realizado un análisis de ANOVA, si no, un análisis de Kruskal-Wallis. El nivel de confianza es del 95% en las pruebas estadísticas. El símbolo '+' en la Tablas significa que la diferencia entre los valores de los tres algoritmos para un problema dado tiene confianza estadística (p-valor por debajo de 0:05).

Para el enfoque a nivel global se ha realizado un conjunto de gráficas. Éstas reflejan la actividad de los algoritmos sobre el conjunto completo de datos. Para su elaboración se ha calculado el porcentaje que cada algoritmo obtiene sobre el total. El significado de cada una de ellas es el siguiente:

**Soluciones encontradas.** Son las soluciones no dominadas encontradas por cada algoritmo sobre el total del conjunto de datos.

**Soluciones con actividad.** Se corresponde con todas aquellas soluciones que han realizado al menos una operación de compra-venta, en el total de la operativa.

**Número de operaciones.** El número total de operaciones de compra-venta realizado por cada algoritmo. Se obtiene como suma de las operaciones realizadas por cada solución individual.

**Duración media.** El tiempo medio que cada solución permanece activa.

**Beneficio.** La ganancia total obtenida por cada algoritmo una vez procesado todo el conjunto de datos. Ésta se obtiene como suma de los beneficios individuales conseguidos por cada solución. La unidad de medida es en "pips".

**Promedio beneficio por operación.** Indica los beneficios medios que obtiene cada solución no dominada encontrada que realiza alguna operación para un algoritmo dado.

En los siguientes apartados se comentan los resultados obtenidos para cada conjunto de datos.

#### 4.3.3.1.- Resultados Conjunto 1

Como se puede observar en la Tabla 24, en el caso de la Métrica de conteo, Mocell posee un número mayor de soluciones no dominadas para el frente de Pareto aproximado. En cuanto a la dispersión generalizada es menor para PESA II. En la métrica de hipervolumen el algoritmo NSGA-II obtiene el mejor valor, y la mayor distancia generacional inversa es para PAES. En principio no hay ningún algoritmo que destaque sobre los demás. En el caso del SPEA-II, no es el primero en ninguna estadística, pero es el segundo en casi todas.

	Métrica de conteo exitoso (MCE)	Dispersión Generalizada (DG)	Hipervolumen (HV)	Distancia Generacional Inversa (DGI)	CE
	$\bar{x}_{IQR}$				
SPEA-II	78 <sub>1.1824</sub>	1.0013 <sub>0.0562</sub>	0.8062 <sub>0.0022</sub>	0.0038 <sub>6.9.e-4</sub>	+
MoCell	82 <sub>1.1913</sub>	1.0016 <sub>0.0751</sub>	0.7492 <sub>0.0055</sub>	0.0046 <sub>5.6.e-4</sub>	+
NSGA-II	43 <sub>0.6581</sub>	1.0407 <sub>0.0254</sub>	0.8113 <sub>0.0045</sub>	0.0038 <sub>4.3.e-4</sub>	+
PAES	26 <sub>0.0914</sub>	0.9572 <sub>0.0436</sub>	0.78 <sub>0.0073</sub>	0.0078 <sub>2.1.e-4</sub>	+
PESA-II	28 <sub>0.9582</sub>	0.9221 <sub>0.0122</sub>	0.7529 <sub>0.0019</sub>	0.0049 <sub>3.1.e-4</sub>	+

Tabla 24.- Evaluación de los resultados obtenidos para las distintas métricas para el conjunto de datos 1

En la Figura 20 se puede ver el detalle numérico de la cantidad de soluciones no dominadas que encuentra cada uno de los algoritmos. En el caso del NSGA-II y Mocell superan las 3000 soluciones encontradas para el total de la operativa realizada con el conjunto de datos uno.




Figura 20.- Cantidad de soluciones no dominadas encontradas.

En cuanto a las gráficas de soluciones encontradas y con actividad (Figura 21), se observa como PESA-II, MoCell y NSGA-II encuentran muchas más soluciones que el resto. En el caso del SPEA-II sorprende la menor cantidad de soluciones encontradas. Aunque en el caso de las que tienen actividad mejora considerablemente.




Figura 21.- Soluciones encontradas y con actividad para el conjunto de datos 1

En la Figura 22 se puede apreciar como el algoritmo SPEA-II, tiene una duración media de sus soluciones mucho mayor. Esto hace pensar que éstas son mucho más robustas en el tiempo que las del resto. Además, también se puede observar que la cantidad de operaciones que genera es prácticamente igual a los demás algoritmos, a pesar de que la cantidad de soluciones encontradas es la mitad. En la operativa real esto significa que con la mitad de expertos se obtiene el mismo rendimiento.




Figura 22.- Número de operaciones totales y duración media de las soluciones para el conjunto de datos 1

En la Figura 23 se observa como el beneficio total es similar en todos los algoritmos, salvo para PAES que es muy bajo. En cuanto al beneficio por operación es sorprendente el rendimiento que alcanza SPEA-II, con un 38%, frente al 18% del siguiente que es MoCell. La ganancia en promedio que consiguen las operaciones que realizan las soluciones no dominadas de SPEA-II alcanzan un rendimiento muy superior a las restantes. Esto se debe principalmente a que las soluciones encontradas por los demás algoritmos (Figura 21), son poco robustas, y que cuando se ponen en funcionamiento para el siguiente intervalo, se comportan peor, incluso generando muchas de ellas pérdidas.

Para el problema que se plantea, lo ideal es maximizar el TWR, y esto se consigue maximizando el número de operaciones de ganancia que realiza cada uno de los expertos operando en paralelo. En general SPEA-II se comporta de una forma muy eficiente, ya que las soluciones no dominadas que genera permanecen más tiempo en funcionamiento y esto permite que operen más, de ahí que obtengan mucha mayor ganancia. También se puede observar cómo NSGA-II se desploma en éste sentido.




Figura 23.- Beneficio Total y beneficio promedio por operación para el conjunto de datos 1.

En resumen, en cuanto a la evaluación de la métrica de conteo, el número de soluciones no dominadas encontradas en el frente de Pareto aproximado es muy similar tanto para el SPEA-II como para MoCell. En el resto de las métricas NSGA-II domina, aunque por una diferencia mínima. En lo que respecta al enfoque global, la duración de las soluciones y su eficiencia es mayor para el algoritmo SPEA- II. Por tanto, esa pequeña ventaja que muestran las evaluaciones de las métricas para MoCell y NSGA-II, se ve claramente contrarrestada con el desempeño a nivel global del SPEA-II. Esto muestra, que para el problema propuesto, un algoritmo que optimice la explotación, con un buen rango de exploración, se va a comportar muy bien. En cada nuevo intervalo se proporciona una fuente de soluciones no dominadas obtenidas de alguna parte del espacio de soluciones, que tiene que competir con las soluciones existentes resultado de la evaluación de los anteriores intervalos, siendo éste un mecanismo de exploración añadido al del propio algoritmo.

#### 4.3.3.2.- Resultados Conjunto 2

	Métrica de conteo exitoso (MCE)	Dispersión Generalizada (DG)	Hipervolumen (HV)	Distancia Generacional Inversa – DGI	CE
	$\bar{x}_{IQR}$				
SPEA-II	19 <sub>1.1913</sub>	<b>0.952</b> <sub>0.0452</sub>	0.728 <sub>0.0051</sub>	0.018 <sub>5.6.e-4</sub>	+
MoCell	35 <sub>1.9231</sub>	1.100 <sub>0.0792</sub>	<b>0.894</b> <sub>0.0059</sub>	0.032 <sub>6.2.e-4</sub>	+
NSGA-II	<b>60</b> <sub>2.0205</sub>	<b>0.952</b> <sub>0.0356</sub>	0.748 <sub>0.0075</sub>	<b>0.010</b> <sub>2.3.e-4</sub>	+
PAES	9 <sub>0.1894</sub>	0.969 <sub>0.0812</sub>	0.761 <sub>0.0038</sub>	0.011 <sub>3.1.e-4</sub>	+
PESA-II	19 <sub>0.251</sub>	0.967 <sub>0.0189</sub>	0.725 <sub>0.0031</sub>	0.011 <sub>3.0.e-4</sub>	+

Tabla 25.- Resultados de los distintos algoritmos para el Conjunto de datos 2



Como se puede observar en la Tabla 25, el algoritmo NSGA-II domina en casi todas las métricas propuestas.

En la Figura 24 se pueden ver los resultados obtenidos para el número de soluciones encontradas y con actividad, se observa como salvo PAES, el resto están muy a la par. Como pasaba en los experimentos anteriores, SPEA-II tiene muchas más soluciones con actividad en comparación con el número de soluciones encontradas. Esto viene a significar que la explotación que hace el algoritmo de las soluciones encontradas es mucho mayor que sus competidores. Esto es muy importante, ya que el tiempo de cálculo del algoritmo no se pierde en encontrar soluciones poco eficientes.




Figura 24.- Soluciones encontradas y con actividad para el conjunto de datos 2

En cuanto al número de operaciones de compra-venta que realizan los algoritmos y el tiempo medio de duración de las soluciones no dominadas (Figura 25), SPEA-II domina con claridad.




Figura 25.- Número de operaciones y duración media de las soluciones para el conjunto de datos 2

En la Figura 26 se puede apreciar el beneficio total y el que obtiene cada solución, y sucede lo mismo que en el conjunto de datos uno. El algoritmo SPEA-II se comporta de manera muy

eficiente con respecto al beneficio por operación. Además en este caso se incrementa sustancialmente la ganancia, si los comparamos con el resto de algoritmos.




Figura 26.- Beneficio Total y beneficio promedio por operación para el conjunto 2

En resumen, a pesar de que el algoritmo NSGA-II se comporta mejor que los demás para las métricas de evaluación que recogen el último intervalo de soluciones no dominadas, en el enfoque global del problema, el SPEA-II domina con claridad sobre todos los demás algoritmos. En este conjunto de datos, este dominio se ha visto incrementado de forma considerable con respecto al anterior, sobre todo en cuanto al beneficio total obtenido, al número de soluciones con actividad y al beneficio promedio.

#### 4.3.3.3.- Resultados Conjunto 3

Como se puede observar en la Tabla 26, los algoritmos SPEA-II y MoCell dominan en todas las métricas propuestas. Aunque el desempeño de ambos es muy parecido, para este conjunto de datos MoCell es mejor.

	Métrica de conteo exitoso (MCE)	Dispersión Generalizada (DG)	Hipervolumen (HV)	Distancia Generacional Inversa – DGI	CE
	$\bar{x}_{IQR}$				
SPEA-II	72 <sub>1.2594</sub>	0.9680 <sub>0.0148</sub>	0.740 <sub>0.0018</sub>	0.0055 <sub>6.1.e-4</sub>	+
MoCell	<b>73</b> <sub>1.2256</sub>	<b>0.9550</b> <sub>0.0486</sub>	<b>0.793</b> <sub>0.0072</sub>	0.006 <sub>6.9.e-4</sub>	+
NSGA-II	53 <sub>1.0205</sub>	1.0015 <sub>0.0786</sub>	0.728 <sub>0.0092</sub>	<b>0.0050</b> <sub>5.9.e-4</sub>	+
PAES	56 <sub>1.4578</sub>	0.9990 <sub>0.0235</sub>	0.733 <sub>0.0064</sub>	0.0051 <sub>5.3.e-4</sub>	+
PESA-II	54 <sub>1.2351</sub>	1.0006 <sub>0.0654</sub>	0.730 <sub>0.0032</sub>	0.0052 <sub>5.8.e-4</sub>	+

Tabla 26.- Resultados de los distintos algoritmos para el Conjunto de datos 3

En cuanto a las gráficas de soluciones encontradas y con actividad, se observa como PESA-II, MoCell y NSGA-II encuentran muchas más soluciones que el resto. Sin embargo, SPEA-II tiene muchas más soluciones con actividad en comparación con el número de soluciones encontradas. En éste conjunto de datos, se hace más patente el rendimiento que encuentra SPEA-II de las soluciones encontradas.




Figura 27.- Soluciones encontradas y con actividad del conjunto de datos 3

En cuanto al número de operaciones que realizan los algoritmos y el tiempo medio de duración de las soluciones no dominadas, SPEA-II domina con claridad ambos apartados.




Figura 28.- Número de operaciones y duración media de las soluciones para el conjunto de datos 3

Para el beneficio total y el que obtiene cada solución sucede exactamente lo mismo que en el conjunto de datos anterior(Figura 28).

En resumen, al igual que en los experimentos realizados para los conjuntos de datos Conjunto 1 y Conjunto 2, SPEA-II es más eficiente en el enfoque global del problema. En cuanto a las métricas de evaluación, los mejores resultados son los obtenidos por MoCell.

El protagonismo de SPEA-II, y su éxito, se debe fundamentalmente a que encuentra buenas soluciones en la parte concreta del espacio de búsqueda que analiza. Aunque, éstas no alcanzan gran diversidad en el total del conjunto del espacio de búsqueda. Si sólo se operará en el siguiente intervalo con éstas soluciones, el desempeño de otros algoritmos como NSGA-II o MoCell sería superior, como así lo muestran los resultados generados por las métricas de evaluación. Sin embargo, como la operativa se realiza con la suma de todas las soluciones no

dominadas encontradas para todos los intervalos, éste consigue un mejor rendimiento, ya que encuentra la dispersión necesaria, qué unida a la mayor eficiencia de sus soluciones, genera una solución global superior.




Figura 29.- Beneficio Total y beneficio promedio por operación para el conjunto de datos 3

#### 4.3.4.- Resumen del análisis de los algoritmos evolutivos seleccionados.

Desde el punto de vista global, y en todos los conjuntos de datos, el algoritmo SPEA-II vence al resto. Los puntos fuertes de éste son los siguientes:

- Se obtiene un mayor beneficio.
- La desviación media es menor.
- El número de operaciones que realiza es mayor.
- Las soluciones son más robustas, su duración media es mayor.
- El número de soluciones no dominadas pertenecientes al frente de Pareto aproximado, se encuentra siempre entre los mejores.
- En la cuantificación del resto de las métricas, a pesar de no ser el mejor, siempre está próximo a éste.

Después de cientos de experimentos realizados, cuyos resultados han sido mostrados en el apartado anterior, el algoritmo seleccionado para el problema propuesto, debido a su alto rendimiento, tanto en beneficio total, como en número de operaciones, y su mínimo riesgo, es el SPEA-II. En los siguientes apartados se analizan sus parámetros, y se realizará un ajuste de los mismos.

## 4.4 Análisis de los parámetros del algoritmo SPEA-II

### 4.4.1.- El operador de inicialización

En la codificación implementada se utilizan cromosomas con diferentes tipos de codificación, esto hace necesario adaptar la inicialización a cada tipo de codificación. La inicialización empleada en todos los casos es del tipo uniforme, donde se genera un número aleatorio

comprendido entre los límites inferior y superior de las variables. El número generado pertenecerá al dominio binario,  $\mathbb{N}$ ,  $\mathbb{R}$  o  $\mathbb{R}^+$  dependiendo del tipo de codificación.

#### 4.4.2.- La función de aptitud

Una vez codificadas las variables de diseño y tras generar las poblaciones de individuos, el siguiente paso es evaluar la aptitud de los mismos. Ésta consistirá en la evaluación del beneficio, la desviación y el número de operaciones. Ese proceso no está sujeto a restricciones. Por tanto, el óptimo global se encontrará localizado en el entorno del espacio de soluciones factibles. Además del óptimo global, es posible encontrar una gran cantidad de óptimos locales, algunos de ellos bastante alejados numéricamente, aunque puede que próximos en cuanto a la localización del global. Evidentemente el entorno del espacio de soluciones factibles no es sencillo de definir en términos de funciones finitas.

#### 4.4.3.- Análisis de los operadores de selección y ajuste de parámetros

Para realizar la selección se han escogido dos operadores diferentes: Torneo y Ruleta. En la Figura 29 se puede comprobar que el comportamiento de sendos operadores de selección es bastante similar, presentando el mejor comportamiento la selección por torneo y peor la selección por ruleta.




Figura 30.- Soluciones encontradas no dominadas y con actividad para ambos operadores de selección.




Figura 31.- Número de operaciones totales y beneficio promedio para ambos operadores de selección.




Figura 32.- Beneficio total para ambos operadores de selección.

Como resultado de los experimentos, el operador de selección utilizado será el de Torneo.

#### 4.4.4.- Análisis de los operadores de cruce y ajuste de parámetros

Se han utilizado dos operadores de cruce diferentes: SBX y PMX. Como se puede apreciar en las figuras siguientes, el operador de cruce SBX presenta un comportamiento mejor que el PMX en todos los rangos estudiados. Esto se debe a que los operadores que son más exploratorios presentan un peor comportamiento frente a los operadores parentocéntricos. Puede verse en estos casos que la convergencia es mucho más elevada, ya que se producen pocos individuos y éstos copan rápidamente el proceso evolutivo. El operador con mejor comportamiento es el SBX ( $\eta = 0.9$ ), el cual fue diseñado específicamente con el fin de favorecer la formación de esquemas en el proceso evolutivo.

Como se puede observar en la Figura 33 la capacidad de exploración de PMX para encontrar nuevas soluciones no dominadas es más reducida, debido a su rápida convergencia, lo cual se traduce en un comportamiento más ineficiente.




Figura 33.- Soluciones encontradas no dominadas y con actividad para ambos operadores de cruce.

En la Figura 46 se puede observar que el número de operaciones totales encontradas para el operador SBX es mucho mayor que para PMX, y que en ambos casos se va incrementando en función de la probabilidad de cruce empleada. En el caso del beneficio promedio de una solución, el margen se acorta entre ambos. Aunque es mejor para el primero, igualmente se incrementa para un mayor valor de la probabilidad de cruce. En el caso de PMX las soluciones encontradas operan menos, aunque tienen un rendimiento parecido a SBX.




Figura 34.- Número de operaciones totales y beneficio promedio para ambos operadores de cruce.

Finalmente, el beneficio total obtenido para el conjunto de datos tratado es el que se muestra en la Figura 35. Éste es una consecuencia de los anteriores resultados, ya que si encontramos más soluciones con actividad, las cuales generan un mayor número de operaciones y beneficio, el resultado final se traduce en una mayor ganancia.




Figura 35.- Beneficio total para ambos operadores de cruce.

Como resultado de los experimentos, el operador de cruce seleccionado para el algoritmo SPEA-II será el SBX, junto con un valor de la probabilidad de 0.9.

#### 4.4.5.- Análisis de los operadores de mutación y ajuste de los parámetros.

En la Figura 36 se puede observar el efecto del ajuste de la probabilidad de mutación. El número de soluciones encontradas es muy similar en los valores 0.07 y 0.08, pero éste último se muestra muy superior en cuanto al número de soluciones que finalmente realizan algún tipo de operativa.




Figura 36.- Soluciones encontradas no dominadas y con actividad para las distintas probabilidades de mutación.

En el resto de estadísticas (Figura 37, Figura 38) también se muestra que 0.08 es muy superior al resto. El valor aconsejado para éste parámetro suele ser 1 dividido por el número total de genes, en éste caso sería de 0.07, pero según los experimentos se alcanza un mejor rendimiento en el entorno de 0.08.




Figura 37.- Número de operaciones totales y beneficio promedio para las distintas probabilidades de mutación.




Figura 38.- Beneficio total para las distintas probabilidades de mutación.

#### 4.4.6.- El tamaño de la población

La selección del tamaño de la población es un elemento muy importante para el problema propuesto, ya que está directamente relacionado con el número de operaciones que el sistema realizará, y por tanto con los resultados finales. En esta sección presentamos los resultados para poblaciones de 10, 50, 100 y 150 individuos respectivamente, y en todos los casos con un tamaño de fichero externo de 100 soluciones.





Figura 39.- Soluciones encontradas no dominadas y con actividad para las poblaciones.




En la Figura 39 se puede apreciar como el mayor número de soluciones encontradas y con actividad se obtiene para una población de 100 individuos. En la Figura 40 se puede ver que el número de operaciones que realiza el sistema sigue incrementándose para valores mayores, aunque el beneficio por operación permanece constante. Y finalmente, en la Figura 41, se puede observar que la ganancia del sistema obtiene su máximo en 100. Por tanto, y según los resultados obtenidos el valor seleccionado será éste último.

En el caso del SPEA-II un elemento que resulta muy influyente es el tamaño del fichero externo, que es el que utiliza para almacenar las mejores soluciones. Una reducción del mismo lleva consigo una caída del rendimiento del sistema muy importante. Los resultados obtenidos indican que el valor óptimo para éste fichero externo también debe ser de 100.



**Figura 40.- Número de operaciones totales y beneficio promedio para las poblaciones.**



**Figura 41.- Beneficio total para las poblaciones.**

Los primeros experimentos se realizaron con una población de 10 individuos y un fichero externo de 10 soluciones, los resultados encontrados eran muy inferiores a los expuestos ( ver Figura 40 y Figura 41 con distintas configuraciones para los operadores de cruce y mutación). Inicialmente se pensó que esto era debido a la cantidad de individuos seleccionados, pero como se puede observar en el estudio realizado para poblaciones entre cien y ciento cincuenta individuos, esto tiene una influencia controlada. La clave se centra más en el tamaño del fichero externo, o para ser más exactos, en la conjunción de ambos. En la Figura 40, se puede ver como se degrada el sistema, ya que el número de soluciones encontradas, en éstos primeros experimentos, no sobrepasaban las sesenta, mientras que ahora son más de mil. También se observa como se han triplicado el número de operaciones que realiza el sistema, lo que conlleva un aumento significativo del rendimiento del mismo.




Figura 42.- Número de soluciones encontradas y de operaciones totales para una población de 10 individuos con un fichero externo de 10 soluciones.




Figura 43.- Beneficio total para una población de 10 individuos con un fichero externo de 10 soluciones.

#### 4.4.7.- Ajuste del número de evaluaciones.

Otro elemento fundamental es la elección del número de evaluaciones más apropiado para la obtención de un mayor número de soluciones no dominadas. En este sentido se ha realizado un experimento donde se muestra que a partir de 25.000 evaluaciones ya no se tienen mejoras significativas (Figura 44).




Figura 44.- Beneficio total para distintas evaluaciones del algoritmo genético.

#### 4.4.8.- Configuración óptima seleccionada

La configuración óptima del algoritmo genético seleccionada es la siguiente:

1. Tamaño de la población:  $\mu = 100$  individuos.
3. Operador de inicialización: aleatorio.
4. Operador de selección: selección por torneo.
5. Operadores de cruce: Operador SBX ( $\eta = 0.9$ )
6. Operador de mutación: mutación polinomial ( $\eta = 0.08$ )
7. Operador de migración: migración de los mejores individuos.
8. Gestión de las restricciones: No existen.

### 4.5 Conclusiones de Capítulo

En este capítulo se ha seleccionado el algoritmo evolutivo, junto con los ajustes necesarios para su implementación final. Las soluciones no dominadas encontradas por éste conformarán el conjunto de expertos que será empleado en la operativa real.

Inicialmente se ha explicado la librería JMetal, que se ha utilizado en este trabajo como “framework” para la operativa con los distintos algoritmos. A continuación se han explicado las distintas métricas empleadas para la evaluación de la calidad de las soluciones encontradas.

En el siguiente apartado se han mostrado los resultados encontrados para los distintos conjuntos de datos. Desde el punto de vista de las métricas los resultados obtenidos no son determinantes, pero desde el enfoque global se ha observado cómo el algoritmo genético SPEA-II mejora al resto.

Finalmente se ha realizado un estudio para el ajuste de todos los parámetros. Los operadores seleccionados y sus valores se acercan bastante a los estándar, quizás el valor de mutación sea un poco mayor de lo habitual. En cuanto al ajuste de la población y su fichero externo, se ha apreciado que es un factor determinante su correcta determinación, ya que en caso contrario, la eficiencia del sistema se vuelve muy pobre.

## 5. Resultados

---

En este capítulo se exponen los resultados experimentales obtenidos. En primer lugar, se realizará un análisis de los valores generados por una solución estándar para cada uno de los genes que componen el cromosoma. Esto permitirá observar si las premisas impuestas en el capítulo dos, para estos parámetros, han sido realizadas de forma correcta. También se estudia la dinámica del sistema, esto permite sintetizar su comportamiento en el tiempo.

Posteriormente, y partiendo de un cromosoma clásico se irán añadiendo estados de libertad para ver cómo la optimización mejora las soluciones no dominadas encontradas. Finalmente se realizará una comparativa con otras estrategias clásicas.

## 5.1.- Introducción

En los siguientes apartados se muestran los resultados obtenidos con la propuesta desarrollada en éste trabajo. Para su validación, éstos son comparados con los obtenidos por estrategias que utilizan valores estándar para caracterizar sus parámetros, y también frente a otro tipo de estrategias. Para ello se han abordado tres fases de experimentación, que se recogen en cada uno de los siguientes apartados.

Fase 1: En el capítulo tres se seleccionaron unos límites a los valores de los parámetros. Éstos fueron obtenidos fruto de la experimentación previa, o por ser los más utilizados en la bibliografía común. Por ello, se va a realizar un estudio previo de los resultados obtenidos para verificar que son adecuados, o si en algún caso es necesario realizar algún tipo de ajuste. Además, observar los valores que toman los genes del cromosoma nos permitirá sacar conclusiones sobre el comportamiento de las soluciones encontradas. A continuación se abordará el comportamiento del sistema, analizando aspectos relacionados con el número de soluciones que obtiene el sistema cada vez que se procesa un conjunto de datos, la duración de la actividad de éstas a lo largo del tiempo, el beneficio que obtienen y el número de operaciones que generan en el mercado. Como se puede observar, esta fase se basa en el análisis del propio sistema y su interacción en tiempo real con el mercado.

Fase 2: Ésta tiene un doble objetivo, por un lado comparar los resultados obtenidos por la solución implementada, frente a aquellas estrategias con indicadores técnicos que utilizan valores estándar para sus parámetros y, por otro lado, ver como, conforme se aumentan grados de libertad al algoritmo, se mejoran dichos resultados. Esto último, añade de manera intrínseca el valor que los algoritmos evolutivos aportan, como mejora, a la operativa de los mercados bursátiles, más concretamente al mercado de divisas.

Fase 3: El objetivo de esta fase es comparar el beneficio de la técnica desarrollada en esta tesis con estrategias habituales como *Buy & Hold* [Chen02].

Para la comparación se han empleado los conjuntos de datos explicados en el capítulo dos.

## 5.2. Análisis de los valores obtenidos por los parámetros

Como se ha indicado anteriormente, en los siguientes apartados se va a realizar un análisis de los valores encontrados en los parámetros, para las distintas soluciones generadas por el algoritmo. Para ello, se ha seleccionado previamente un conjunto de 100 experimentos al azar, y se ha aplicado un estudio estadístico de t-student [Benjamin70] [Canavos87] para los resultados de las distribuciones obtenidos por éstos, y se ha podido concluir que no existe significancia estadística entre la elección de cualquiera de ellas. Además, la desviación típica observada es de un orden muy pequeño, en torno a  $10^{-5}$ . Por tanto, se va a simplificar el estudio a una única muestra, que denominaremos experimento representativo, y que será la utilizada para analizar y validar los valores obtenidos a partir de las restricciones propuestas originariamente.

### 5.2.1.- Cromosomas relacionados con los indicadores.

#### 5.2.1.1.- MACD

En las Figura 45, 46 y 47 se pueden observar los valores obtenidos para los parámetros estructurales del MACD en su progreso a lo largo del tiempo. En el eje-x se representa el número de soluciones encontradas, en el orden en que han ido apareciendo en el tiempo. El eje-y constituye el valor que ha tomado el parámetro en “ticks”, que es la unidad de tiempo en la que son tomadas las muestras. Los valores propuestos inicialmente estaban en un rango de [1-100], y como se puede observar el valor máximo es alcanzado por algunas soluciones, aunque generalmente se sitúa en valores menores. Por tanto, una mejora de futuro podría ser ampliar el rango ligeramente a un entorno de 120 ó 150. En cuanto a la dispersión es adecuada, ya que todos los valores son tomados por todos los parámetros.




Figura 45.- Soluciones encontradas en orden de aparición para el parámetro 1.




Figura 46.- Soluciones encontradas en orden de aparición parámetro 2




Figura 47.- Soluciones encontradas en orden de aparición parámetro 3

El número de soluciones que finalmente tienen actividad es un treinta y cinco por ciento inferior al mostrado en las figuras anteriores. Sin embargo, el patrón de dispersión es similar al presentado para el conjunto total de soluciones.

En las Figuras 48, 49 y 50 se pueden ver las distribuciones obtenidas para los valores de los distintos parámetros. En el eje-x se representan los posibles valores que puede tomar un parámetro. En el eje-y se indica la cantidad de soluciones que han tomado ese valor. El indicador MACD nos permite medir la intensidad del mercado, ver si la tendencia del movimiento va a continuar o si se va a girar en sentido contrario. Como se puede observar, los valores pequeños predominan, y esto significa que el indicador desecha la información que se produce en los periodos previos lejanos en el tiempo. Es decir, con unos cuantos valores de precios le es suficiente para determinar la intensidad y la tendencia del mercado. Este comportamiento está influenciado por el valor de las ventanas en las que opera, que son de un tamaño inferior para generar un mayor número de operaciones y por tanto un mayor beneficio. Los valores estándar en la bibliografía son 12, 26, 9. En los experimentos realizados estos números no parecen significativos.




Figura 48.- distribución de valores para el parámetro 1 del MACD






Figura 49.- Cantidad de valores encontrados parámetro 2 del MACD

En la Figura 50 tenemos los valores relacionados con la denominada línea de señal (parámetro 3) que no es más que una media móvil exponencial de  $x$  “ticks” del MACD. En este caso la distribución es mucho más dispersa que en los parámetros anteriores. El comportamiento de este parámetro es sorprendente en cuanto a que normalmente éste suele tener el menor tamaño de todos y en nuestro trabajo es justamente al contrario.




Figura 50.- Cantidad de valores encontrados parámetro 3 del MACD

En la Figura 51 se puede ver en conjunto los valores que toman los tres parámetros estructurales del MACD. En este caso es para una muestra, que incluye sólo las soluciones no dominadas al término del experimento. Se puede observar que en general no tienen ninguna similitud, salvo en algún conjunto contiguo. Esto es debido a que el algoritmo encuentra grupos de soluciones no dominadas similares en la misma evaluación. En esta figura se muestra que no existe un conjunto estándar de valores para el MACD, y que éstos pueden ser muy variados en función de la solución encontrada.




Figura 51.- MACD para las soluciones no dominadas del último intervalo. Parámetro 1: azul; Parámetro 2: rojo; Parámetro 3: verde

### 5.2.1.2.- Cromosomas relacionados con la generación de señales para el MACD.

En este apartado se muestran los valores obtenidos por los parámetros que están relacionados con la sensibilidad que debe tener el MACD a la hora de emitir señales de compra-venta. En la Figura 52 se puede apreciar la variación que supone la toma de un valor u otro tanto para la compra como para la venta. Por ejemplo, en el caso de una operación de venta, el valor máximo de 0.1 indicaría que la señal se produce para un valor 0.1 menor que el tamaño que toma la línea anterior del Histograma. Es decir, que se toma cuando la línea actual es menor que la anterior y además lo es en una distancia determinada.




Figura 52.- Representación del las distancias en el Histograma del MACD

En la Figura 53 se observa cómo los valores que toma el parámetro en el caso de la distancia de compra, incluyen todo el rango posible, centrándose en valores más próximos al cero. Es decir, en la mayor parte de los casos la generación de la señal se produce para distancias próximas entre la barra actual y la anterior del histograma. En general, el intervalo aconsejado

por los analistas, es con valores mayores de cero, y esto como se puede ver no es lo que se refleja en el gráfico.




Figura 53.- Distancia de compra para el MACD (parámetro  $MACD_{pa}$ )

En la Figura 54 se pueden apreciar los resultados obtenidos para la distancia entre la barra actual y la anterior del histograma del MACD, en el caso de operaciones de venta. Los valores se ajustan más a los previstos en la bibliografía, y se centran en el intervalo entre 0 y 0.1.




Figura 54.- Distancia de venta para el MACD (parámetro  $MACD_{pb}$ )

En conclusión, las señales que ha generado el MACD para las ventas están más acotados que en el caso de las compras. Además en el caso de las ventas la distribución de valores se centra en 0.05, y en las compras en 0. Esto indica que las señales de venta siempre se producen cuando la tendencia empieza a caer, y son más independientes de la solución concreta aportada por el algoritmo. En el caso de las compras no hay un patrón claro, y parece muy dependiente del resto de parámetros que componen la solución. En cuanto a los rangos propuestos de -0.1 a 0.1 parecen adecuados.

### 5.2.1.3.- Estocástico.

En las Figuras 55, 56 y 57 se pueden observar los valores para los parámetros estructurales del estocástico en su progreso a lo largo del tiempo. En el eje-x se representa el número de soluciones encontradas, en el orden en que han ido apareciendo a lo largo del tiempo. El eje-y constituye el valor que ha tomado el parámetro en “ticks”, que es la unidad de tiempo en la que son tomadas las muestras. Los intervalos seleccionados inicialmente fueron de [1-100], [1-25] y [1-25] respectivamente para cada parámetro. Este indicador le da seguimiento a la velocidad de cambio o momentum del precio. Como regla general, el momentum cambia de dirección antes de que lo haga el precio. En este caso los valores del parámetro 1 determinan la información necesaria para el cálculo del momentum, mientras que los dos siguientes realizan un ajuste fino de éste. Se puede ver que la dispersión es adecuada y que el valor máximo es alcanzado por un número mínimo de valores.




Figura 55.- Soluciones encontradas en orden de aparición para el parámetro 1 del estocástico




Figura 56.- Soluciones encontradas en orden de aparición para el parámetro 2 del estocástico




Figura 57.- Soluciones encontradas en orden de aparición para el parámetro 3 del estocástico

En las Figuras 58, 59 y 60 se pueden ver las distribuciones obtenidas para los valores de los distintos parámetros de este indicador. Existe una distribución bastante uniforme para el primero, y los siguientes toman valores más cercanos a uno. El enfoque tradicional establece valores de 14, 3, 3 para la determinación de los niveles que marcan el punto sobre el cual el mercado está en condición de sobre compra o de sobreventa. Sin embargo, en éste trabajo no parecen valores especialmente relevantes, ya que el grado de dispersión es mucho mayor.

Los resultados obtenidos son coherentes y los valores seleccionados también parecen correctos. Aunque como trabajo futuro sería interesante ampliar el intervalo del primer parámetro, y analizar el comportamiento de las soluciones para ver si aportan un mejor rendimiento.




Figura 58.- Distribución de valores para el parámetro 1 del estocástico




Figura 59.- Distribución de valores para el parámetro 2 del estocástico




Figura 60.- Distribución de valores para el parámetro 3 del estocástico

En la Figura 61 se puede ver en conjunto los valores de los parámetros estructurales del indicador estocástico seleccionados para el conjunto de soluciones no dominadas resultantes al final del experimento. Se puede observar el predominio del primer parámetro sobre los anteriores, como así lo muestran las distribuciones obtenidas. Este proceder es el habitual, implica que el suavizado que se realiza del primer parámetro es pequeño. Este gráfico también muestra que no existe un conjunto estándar de valores para el estocástico, y que éstos pueden ser muy variados en función de la solución encontrada. Por otra parte, el comportamiento es parecido al que se obtenía en el indicador MACD, en cuanto a que en algunos casos se encuentran conjuntos similares de soluciones. Esto como ya se indicó anteriormente se debe al propio funcionamiento del algoritmo evolutivo SPEA-II.




Figura 61.- Estocástico para las soluciones no dominadas del último intervalo. Parámetro 1: azul; parámetro 2: rojo; parámetro 3: verde

#### 5.2.1.4.- Cromosomas relacionados con la generación de señales para el estocástico.

En la Figura 62 se pueden apreciar los resultados obtenidos para el parámetro  $EST_{pa}$ . La literatura recomienda un valor superior a 80 para la zona de sobrecompra, y por tanto, para ejecutar una señal de venta. Los resultados obtenidos cubren todo el rango posible de valores, pero mayoritariamente se ajustan al valor límite de 50. Esto indica que en la mayoría de los casos, cuando las líneas cruzan el valor central, se emite una señal de venta. La sensibilidad para este parámetro es muy reactiva.




Figura 62.- Resultados obtenidos para el parámetro  $EST_{pa}$

En la Figura 63 se pueden observar los resultados obtenidos para el  $EST_{pb}$ . El rango de valores que se cubre es completo, aunque centrados en valores próximos a 50, como sucedía para  $EST_{pa}$ . La literatura recomienda como zona de sobreventa valores inferiores a 20.




Figura 63.- Resultados obtenidos para el parámetro  $EST_{pb}$

Los resultados obtenidos para estos dos parámetros están lejos de los clásicos valores de veinte y ochenta que se recomiendan en la literatura clásica, y se concentran más en rangos cercanos a cincuenta en ambos casos. Esto hace que se generen más señales de operación, ya que el tamaño de las zonas de toma de decisiones es mayor, y esto provoca que el sistema sea mucho más reactivo. También hay que pensar que los datos que se introducen en el sistema son “tick” a “tick” y esto hace llevar a que la variación de la evolución de los precios sea menos abrupta que para sistemas de quince minutos o una hora. Por tanto, la dinámica del sistema considera que una variación de la tendencia por encima de cincuenta, es suficiente para generar una señal de operación.

### 5.2.3.- Cromosomas relacionados con la operativa del mercado.

En esta sección se van a analizar los resultados obtenidos por los denominados parámetros de mercado. Un “stop-loss” es una orden que permite detener las posibles pérdidas. Uno de los objetivos de cualquier sistema de “trading” es mantener el riesgo siempre bajo control. Para ello, es necesario conocer las posibles pérdidas antes de establecer cualquier tipo de posición. Realmente el “stop-loss” es una orden de venta encubierta en la propia compra, ya que sólo se ejecutará si el precio cae lo suficiente como para generar la pérdida máxima admisible. Las órdenes que no se ejecutan no suponen ningún coste; por tanto, controlar el riesgo en las operaciones ahorra disgustos sin generar coste.

En la Figura 64 se pueden apreciar los valores obtenidos para el “stop-loss” en éste trabajo. Inicialmente se observa cómo se cubre todo el rango posible de valores. Esto significa que el número de estrategias gestionadas por el algoritmo es muy amplio. Los valores pequeños significan operativas cortas con un riesgo mínimo, mientras que los valores grandes son todo lo contrario, operaciones más largas con un riesgo elevado en el caso de que el precio no llegue a alcanzar el valor esperado.






Figura 64.- Resultados para el parámetro "stop-loss"

En la Figura 65 se pueden observar los resultados obtenidos para el "take-profit". Éste es muy similar al "stop-loss", pero en vez de cerrar la posición para no perder más, éste lo hace cuando llega a un precio objetivo fijado con anterioridad (nuestra meta para esa operación). En éste caso, la tendencia es clara, se maximiza la rápida recogida de beneficios.




Figura 65.- Resultados para el parámetro del "take-profit"

El "trailing-stop" es una forma de maximizar los beneficios cuando el mercado se mueve a nuestro favor, y pone un stop dinámico que se ajusta a las necesidades para sacar el máximo provecho a cada orden. Esta estrategia de utilizar el "trailing-stop" es muy útil para asegurar las ganancias en una posición determinada cuando el mercado se ha movido en el sentido adecuado, y para acompañar los beneficios en tramos definidos por éste. En la Figura 66, se observa su comportamiento, sorprende la amplitud del rango que obtiene, ya que serían más lógicos valores más pequeños. Esto se puede deber a la inmediatez con la que el sistema realiza la ganancia. Estos valores hacen que este parámetro pierda influencia en algunas soluciones y permite que el sistema se comporte como si únicamente tuviera los valores de

“stop-loss” y “take-profit” a la hora de la toma de decisiones. Esto está dentro de la lógica, puesto que hay muchas operaciones que no tienen este parámetro dentro de su operativa.




Figura 66.- Resultados para el parámetro “Trailing-Stop”

El funcionamiento del sistema se ve claramente caracterizado en las figuras anteriores, ya que se fija la recogida de ganancias en pequeños valores, o, en los casos en los que la evolución de los precios lo permita, se mantienen las posiciones hasta que se llega a la meta anteriormente determinada.

En el caso del “stop-loss” y el “take-profit” se podría incluso ampliar el rango inicialmente propuesto, ya que hay valores que llegan al máximo. Esto tendría sentido desde el punto de vista teórico, pero en la práctica el riesgo es demasiado elevado puesto que el capital invertido aumenta proporcionalmente estos rangos; por tanto no se realizará este cambio.

#### 5.2.4.- Cromosomas relacionados con las ventanas temporales.

En la Figura 67 se observan los resultados obtenidos para la ventana del MACD. El valor límite no es alcanzado por ninguna solución, y el rango es cubierto completamente. Esto indica que el sistema prefiere trabajar en ventanas pequeñas y que el marco de la operativa no es para nada determinista. En la Figura 68 se aprecian los resultados para el tamaño de la ventana del estocástico, que se ve que opera en ventanas más pequeñas que el MACD. Inicialmente esto debería ser así, ya que la ventana del MACD debía marcar la tendencia, mientras que el estocástico debía de encontrar las señales dentro de la tendencia, como se explicó en el capítulo 3. Sin embargo, se dejó que fuera el propio sistema el que determinara esta actuación y no se introdujo ningún tipo de restricción sobre el mismo. Por tanto, se ve como éste ha racionalizado su comportamiento y se ha adaptado a la lógica de la estrategia inicialmente propuesta en este trabajo.

Por otra parte, el conjunto de datos es el mismo para todas las soluciones, y sin embargo se puede observar que la variabilidad de la escala temporal seleccionada por éstas es enorme. En los experimentos que se presentarán en el apartado 5.4 se verá que la reducción de estas escalas conduce a resultados peores en todos los sentidos. Ésta es una de las grandes aportaciones de esta tesis, donde el paradigma dominante es encontrar una solución en un

marco temporal concreto y, en éste trabajo se propone que la solución y el marco temporal conforman un todo difícil de definir a priori, como se puede observar en los resultados obtenidos.




Figura 67.- Resultados del parámetro “tamaño de la ventana” del MACD




Figura 68.- Resultados del parámetro “tamaño de la ventana” del Estocástico

### 5.3.- Dinámica del sistema.

La herramienta desarrollada en este trabajo se basa en la creación constante de nuevas soluciones conforme se van generando nuevos datos. En concreto, cada once mil quinientos datos se produce un nuevo procesamiento, que es el tiempo estimado que tarda el algoritmo en calcular un nuevo conjunto de soluciones. Después de esto, el sistema realiza un test de dominancia y obtiene el conjunto de soluciones no dominadas que operaran en los siguientes intervalos. Este proceso continúa hasta que se trata el conjunto total de datos. Cuando la

máquina opera en tiempo real, éste proceso es infinito. Para el estudio de la dinámica del sistema se van a analizar las soluciones que se obtienen y su ciclo de vida. Además, se observará el beneficio generado y el número de operaciones realizadas a su cierre, en cada intervalo.

Para su representación se utilizarán tres gráficos distintos: tiempo de vida de las soluciones encontradas, beneficio y número de operaciones realizadas. En el primero (Figura 69, Gráfico a), se muestra el total de soluciones encontradas, las que se extinguen en un intervalo determinado y el alcance máximo de las mismas. Por ejemplo, en el procesamiento 1, en el primer intervalo se cierran treinta y cinco soluciones, y en el siguiente veinticinco, y así sucesivamente hasta completar el conjunto total. Las soluciones generadas tienen un alcance máximo de nueve intervalos, y son un total de noventa y cinco. Cuando una solución se cierra se debe siempre a que existen otras que la dominan. Es decir, que si una solución genera pérdida en un intervalo concreto o en un conjunto de ellos, no será eliminada. Esta decisión trata de evitar que buenas soluciones sean cerradas si su evolución en algunos intervalos no ha sido satisfactoria.

En el gráfico de beneficio (Figura 69, Gráfico b), se puede observar la ganancia obtenida por todas las soluciones que se extinguen en un intervalo concreto. El origen siempre es el primero de ellos. Por ejemplo, en el procesamiento 1, en el intervalo 1, las soluciones que se cierran no tienen beneficio alguno, ya que nunca llegan a operar, se generan y mueren en el mismo intervalo inicial. En el intervalo 2, el beneficio obtenido por las 25 soluciones que se cierran es de  $0.22 \times 10^5$  "pips". Sin embargo, en el intervalo 6, el número de operaciones que cierran es menor, en concreto nueve, y el beneficio que se obtiene es superior, de  $0.35 \times 10^5$  "pips". Normalmente, cuanto más tiempo permanecen activas las soluciones mayor beneficio generan.

En cuanto al gráfico que representa el número de operaciones realizadas (Figura 69, Gráfico c), éste permite ver la cantidad de entradas producidas por las soluciones no dominadas que se cierran en ese intervalo. Para el ejemplo del procesamiento 1, se puede observar que existe un pico para el intervalo 6. Es decir, en éste intervalo se han cerrado las soluciones con un mayor desempeño.

En la Figura 69 se muestran los diez primeros procesamientos consecutivos del sistema. Cada uno representa la generación de un nuevo conjunto de soluciones y su ciclo de vida posterior. El experimento completo se compone de un total de 46 procesamientos, del cual sólo se muestran los diez primeros, por ser representativos del resto. A continuación se van a analizar las características comunes que se pueden apreciar en cada uno de los gráficos y su significado.


**Gráfico a, número de soluciones encontradas:** en el eje-x se representa el número de intervalos en los que se mantiene abierta alguna solución generada por ese procesamiento. En el eje-y se muestra la cantidad de soluciones que son cerradas en ese intervalo. Se puede observar que el número de soluciones activas se va degradando en el tiempo. En general, en los cuatro primeros intervalos, el ochenta por ciento de las soluciones son dominadas por otras. Para el conjunto observado, la duración máxima de una solución es de trece intervalos, y la mínima de siete. Esto muestra la importancia de la generación constante de soluciones

conforme llegan nuevos datos, ya que la degradación que sufren las soluciones para nuevos conjuntos de datos es muy agresiva.


**Gráfico b, beneficio obtenido por un conjunto de soluciones al cierre en un intervalo concreto:** el eje-x es igual que en el caso anterior, y en el eje-y se muestra el beneficio obtenido por aquellas soluciones que se cierran en ese intervalo. En general casi todos los cierres son positivos. Sin embargo, la variabilidad en cuanto a beneficios es alta. Los procesamientos dos, siete y ocho obtienen mayor beneficio que el resto. También se puede ver que hay soluciones que generan un gran beneficio. Por ejemplo, en el procesamiento diez la solución que se extingue en último lugar genera casi todo el beneficio. Los beneficios para todas las gráficas están calculados en “pips”, que es la unidad mínima con la que se opera en el mercado de divisas.

**Gráfico c, número de operaciones:** el eje-x es igual que en el caso anterior, y en el eje-y se muestra el número de operaciones realizadas por las soluciones cerradas en ese intervalo. Normalmente las mejores operaciones se mantienen más tiempo, generan un mayor beneficio, y esto se debe al número total de operaciones que realizan. Sin embargo, también hay otras, como por ejemplo la que finaliza en el intervalo doce del procesamiento nueve, que genera una gran cantidad de operaciones y sin ninguna ganancia. También se puede observar que hay procesamientos como el siete y el ocho que generan gran número de soluciones en comparación con otros. En realidad no existe un patrón definido para el desempeño en el número de operaciones.


#### Procesamiento 1.




#### Procesamiento 2.




## Procesamiento 3.




## Procesamiento 4.




## Procesamiento 5.




## Procesamiento 6.




## Procesamiento 7.



## Procesamiento 8.



## Procesamiento 9.



## Procesamiento 10.





Figura 69.- Evaluaciones del procesamiento del 1 al 10. Gráfico a: ciclo de vida de las soluciones encontradas. Gráfico b: beneficio final obtenido por las soluciones en ese intervalo. Gráfico c: total de operaciones realizadas por las soluciones a su cierre.

En la Figura 70 se puede observar el resumen de los resultados obtenidos para las soluciones encontradas en los diez procesamientos analizados anteriormente. En el eje-x se representan los diez procesamientos, y en el eje-y el valor que toma en función de la gráfica. A modo de ejemplo, se puede ver que en el primer intervalo el número de soluciones encontradas han sido noventa y cinco, y que han obtenido un beneficio de  $1.5 \times 10^5$  “pips”, para un total de veintiuna mil operaciones. El número de soluciones que se obtienen (Figura 70. Gráfico a) depende única y exclusivamente del algoritmo, y se observa que es bastante desigual. En cuanto al beneficio obtenido (Figura 70. Gráfico b), hay intervalos con un gran beneficio y el resto se mantiene en torno a una mediana de  $1.5 \times 10^5$  “pips”. Este parámetro no está directamente relacionado con el número de operaciones, ya que existen intervalos con un gran número de operaciones, y sin embargo, el beneficio está en torno a la mediana.



**Figura 70.- Resumen de resultados obtenidos por las soluciones en cada procesamiento en media. Gráfico a: Número de soluciones encontradas. Gráfico b: beneficio obtenido. Gráfico c: total de operaciones.**

En conclusión, la desviación en cuanto al número de soluciones que obtiene el algoritmo es elevada. Esto no implica un empeoramiento del rendimiento del sistema, ya que como se puede observar en los distintos procesamientos, un mayor número de soluciones no implica un mayor beneficio. La degradación de las soluciones y el cierre en los primeros intervalos tienen un comportamiento normal, ya que hay muchas soluciones cuyo margen de ganancia es pequeño, y en cuanto cambia el conjunto de datos sobre los que se produce la evaluación, su rendimiento empeora. Además, deben competir con las soluciones encontradas para ese conjunto, que normalmente para ganancias pequeñas se ajustan mejor y de ahí que dominen a las anteriores y produzcan su cierre. Sin embargo, éste cierre prematuro, como se puede observar en el intervalo dos, qué sería el más crítico, no genera pérdidas. Es decir, las soluciones tienen un margen de ganancia pequeño y son perecederas en el corto plazo, pero no significa que el tiempo en el que operan lo hagan con malos resultados. En cuanto al número de soluciones que perduran en el tiempo, generalmente el valor tiende a uno.

Estudiando el beneficio (figura 70, gráfico b) en media todos los intervalos generan ganancia, lo cual indica la bondad del uso de los algoritmos evolutivos con éste tipo de soluciones. En lo que respecta al número de operaciones (figura 70, gráfico c), se puede apreciar que en general existe una relación con el número de soluciones obtenidas por el algoritmo. Esto es normal, ya que cada solución generará soluciones que se sumarán a la cantidad total. De todas formas, lo que sí se ha observado es que las soluciones cuyo primer objetivo tiene una ganancia pequeña, realiza un número pequeño de operaciones, por el motivo explicado en el párrafo anterior. Si muchas de las soluciones encontradas por el algoritmo se encuentran cerradas en los primeros intervalos, el número de operaciones que finalmente encontramos es menor de lo esperado;



esto pasa por ejemplo en el procesamiento uno, donde encontramos un gran número de soluciones, pero sin embargo, el número de operaciones es significativamente inferior al esperado. Por el contrario, los procesamientos seis y siete, que tienen una curva de degradación menor en cuanto al número de soluciones cerradas, sí encuentran un número final de operaciones acorde a lo esperado. Uno de los aportes en la solución final implementada es la aplicación de un filtro que reduzca este efecto.

#### 5.4.- Comparativa de resultados con parámetros estándar.

En este apartado se va a estudiar la influencia que tienen los distintos parámetros del cromosoma en cuanto a la obtención del resultado final. Para ello se van a utilizar cinco configuraciones distintas. La primera sólo permitirá la variabilidad en los parámetros de mercado, los cuales fluctuarán libremente en todas las configuraciones, el resto de los parámetros permanecerán fijos con los valores estándar (ver Tabla 27). En la segunda, sólo los parámetros del MACD pueden tomar distintos valores (ver Tabla 28). En la tercera, será el estocástico el que pueda fluctuar y el resto permanecerá fijo (ver Tabla 29). En la cuarta sólo permanecerán fijos los parámetros pertenecientes a la selección de los marcos temporales (ver Tabla 30), y finalmente en la quinta se permitirán todos los grados de libertad (ver Tabla 31).

Para la realización de estos experimentos se han utilizado los conjuntos de datos expuestos en el capítulo 3, referentes a la divisa EUR/USD, pero en este caso sólo se han utilizado los trescientos mil primeros datos. Esta limitación no restringe en ningún caso los resultados finales, ya que lo único que reduce es el tiempo de procesamiento. Por tanto, los periodos para los conjuntos seleccionados serán los siguientes: 29/03/2004 al 21/04/2004, 02/04/2006 al 16/05/2006 y 30/03/2008 al 06/05/2008.

Dado que la ejecución de un proceso de optimización con algoritmos evolutivos tiene un componente estocástico, para cada conjunto de datos se han realizado cien experimentos independientes. Además, para establecer la relevancia estadística de los resultados y comprobar que éstos no son fruto del azar, se ha realizado el test de student [Benjamin70] [Canavos87]. Para llevarlo a cabo, se ha tomado como conjunto inicial los resultados obtenidos por cien configuraciones fijas elegidas al azar, y se ha comparado con la primera configuración propuesta en este apartado. A continuación se ha ido comparando cada una de ellas con la siguiente; de esta forma se ha podido observar cómo la inclusión de nuevos grados de libertad sobre la configuración inicial la mejora, y cómo el resultado obtenido tiene significancia estadística.

MACD			ESTOCÁSTICO			ESCALAS TEMP.		MERCADO			Param. MACD		Param. ESTOCÁSTICO	
MACD <sub>a</sub>	MACD <sub>b</sub>	MACD <sub>c</sub>	EST <sub>a</sub>	EST <sub>b</sub>	EST <sub>c</sub>	ESCT <sub>1</sub>	ESCT <sub>2</sub>	SL	TP	TS	MACD <sub>pa</sub>	MACD <sub>pb</sub>	EST <sub>pa</sub>	EST <sub>pb</sub>
12	26	9	14	3	3	60	15	5-25	5-50	5-25	0	0	80 - 100	0-20

Tabla 27.- Valores de la optimización multi-objetivo sin grados de libertad (Comparativa 1).

MACD			ESTOCÁSTICO			ESCALAS TEMP.		MERCADO			Param. MACD		Param. ESTOCÁSTICO	
MACD <sub>a</sub>	MACD <sub>b</sub>	MACD <sub>c</sub>	EST <sub>a</sub>	EST <sub>b</sub>	EST <sub>c</sub>	ESCT <sub>1</sub>	ESCT <sub>2</sub>	SL	TP	TS	MACD <sub>pa</sub>	MACD <sub>pb</sub>	EST <sub>pa</sub>	EST <sub>pb</sub>
1-100	1-100	1-100	14	3	3	60	15	5-25	5-50	5-25	0	0	80 - 100	0-20

**Tabla 28.- Valores de la optimización multi-objetivo con grados de libertad en los parámetros del MACD (Comparativa 2).**

MACD			ESTOCÁSTICO			ESCALAS TEMP.		MERCADO			Param. MACD		Param. ESTOCÁSTICO	
MACD <sub>a</sub>	MACD <sub>b</sub>	MACD <sub>c</sub>	EST <sub>a</sub>	EST <sub>b</sub>	EST <sub>c</sub>	ESCT <sub>1</sub>	ESCT <sub>2</sub>	SL	TP	TS	MACD <sub>pa</sub>	MACD <sub>pb</sub>	EST <sub>pa</sub>	EST <sub>pb</sub>
12	26	9	1-100	1-25	1-25	60	15	5-25	5-50	5-25	0	0	80 - 100	0-20

**Tabla 29.- Valores de la optimización multi-objetivo con grados de libertad en los parámetros del Estocástico (Comparativa 3).**

MACD			ESTOCÁSTICO			ESCALAS TEMP.		MERCADO			Param. MACD		Param. ESTOCÁSTICO	
MACD <sub>a</sub>	MACD <sub>b</sub>	MACD <sub>c</sub>	EST <sub>a</sub>	EST <sub>b</sub>	EST <sub>c</sub>	ESCT <sub>1</sub>	ESCT <sub>2</sub>	SL	TP	TS	MACD <sub>pa</sub>	MACD <sub>pb</sub>	EST <sub>pa</sub>	EST <sub>pb</sub>
1-100	1-100	1-100	1-100	1-25	1-25	60	15	5-25	5-50	5-25	0.100 - 0.100	0.100 - 0.100	50 - 100	1-50

**Tabla 30.- Valores de la optimización multi-objetivo con grados de libertad para los parámetros de ambos indicadores (Comparativa 4).**

MACD			ESTOCÁSTICO			ESCALAS TEMP.		MERCADO			Param. MACD		Param. ESTOCÁSTICO	
MACD <sub>a</sub>	MACD <sub>b</sub>	MACD <sub>c</sub>	EST <sub>a</sub>	EST <sub>b</sub>	EST <sub>c</sub>	ESCT <sub>1</sub>	ESCT <sub>2</sub>	SL	TP	TS	MACD <sub>pa</sub>	MACD <sub>pb</sub>	EST <sub>pa</sub>	EST <sub>pb</sub>
1-100	1-100	1-100	1-100	1-25	1-25	1-250	1-250	5-25	5-50	5-25	-0.100 - 0.100	0.100 - 0.100	50 - 100	1-50

**Tabla 31.- Valores de la optimización multi-objetivo con todos los grados de libertad (Comparativa 5).**

A continuación se presentan los resultados para cada uno de los conjuntos, y posteriormente se comentarán las cuestiones más relevantes de los resultados obtenidos.

#### 5.4.1.- Resultados conjunto 1.

En la Figura 71 se pueden ver los resultados obtenidos para el número de soluciones encontradas y las que posteriormente realizan alguna operación en este conjunto. La configuración cinco tiene un 48.78% sobre el total de soluciones encontradas, seguida por la cuatro con un total de 38.51%. En cuanto a aquellas soluciones que consiguen realizar alguna operación, es decir que tienen actividad, los datos obtenidos son 47.60% y 39.46% respectivamente. El resto de resultados pertenecientes a las demás configuraciones son prácticamente insignificantes en comparación con éstos. La diferencia entre las dos mejores es de un 8% aproximadamente. En cuanto a la desviación típica es menor en la cuarta configuración que en la quinta, más concretamente 3.62% frente a 10.73%. Esto se debe fundamentalmente a la ampliación del espacio de búsqueda, ya que existen un mayor número de soluciones encontradas por el algoritmo, y esto hace que aumente la desviación típica.




Figura 71.- Resultados para las estrategias referentes al número de soluciones encontradas y la actividad.

Como se puede observar en la Figura 72, las tres primeras configuraciones no logran encontrar beneficio para este conjunto de datos. La cuatro y cinco logran un 44.68 % y un 62.83% respectivamente. La mejora del uso de ventanas fijas con respecto a aquéllas configuraciones en donde el algoritmo realiza su elección es de un 18%, a favor de éstas últimas. En cuanto al número de operaciones realizadas, se aprecia que igualmente estas configuraciones llevan a cabo el mayor número de operaciones con un 32.54% y un 63.20% respectivamente. En este caso la cinco casi dobla a la cuatro y esto se debe, a que las ventanas que utiliza esta última son más pequeñas y por tanto, se realiza un mayor número de operaciones.




Figura 72.- Resultados para las estrategias referentes al beneficio total y al número de operaciones realizadas

En la Figura 73 se puede apreciar el promedio de beneficio que genera cada operación. Las tres primeras generan pérdidas, mientras que la cuarta y quinta configuración generan el total de las ganancias, concretamente el 168.34% y el 154.44% respectivamente. Este valor ha sido alcanzado sumando el total del beneficio obtenido por cada operación y a partir de ahí, se ha calculado el porcentaje que aporta cada configuración al valor final. La diferencia a nivel de

operación no es elevada, pero ésta diferencia se acrecienta cuando se considera el conjunto total de soluciones encontradas y las operaciones que realiza cada una de las configuraciones.




Figura 73.- Resultados para las estrategias referentes al promedio de beneficio por operación conseguido

El resumen de los datos obtenidos en todas las configuraciones analizadas se presenta en las Tabla 32 y 33.

Promedio					
	Total soluciones encontradas	Actividad	Beneficio	Número Operaciones	Beneficio Promedio x operación
Conf.-1	3.49 %	3.30%	-1.71%	0.67%	-68.75%
Conf.- 2	6.11%	6.56%	-4.73%	1.67%	-117.61%
Conf.- 3	3.11%	3.08%	-1.07%	1.91%	-36.42%
Conf.- 4	38.51%	39.46%	44.68%	32.54%	154.44%
Conf.- 5	48.78%	47.60%	62.83%	63.20%	168.34%

Tabla 32.- Resumen del promedio de los datos obtenidos para todas las configuraciones del conjunto 1

Desviación típica					
	Total soluciones encontradas	Actividad	Beneficio	Número Operaciones	Beneficio Promedio x operación
Conf.- 1	11.63%	7.42%	17.37%	34.82%	33.68%
Conf.- 2	16.56%	19.60%	0%	0%	0%
Conf.- 3	13.68%	27.63%	5.70%	22.30%	3.14%
Conf.- 4	3.62%	3.34%	6.58%	5.95%	3.52%
Conf.- 5	10.73%	6.09%	7.18%	9.43%	13.25%

Tabla 33.- Resumen de la desviación típica de los datos obtenidos para todas las configuraciones del conjunto 1

En la Tabla 34 se muestran los resultados obtenidos en el test de student para establecer la relevancia estadística de los mismos. Este estudio se muestra sólo para el beneficio total y

promedio por operación, aunque en el resto de casos es similar. El resultado de la configuración uno se ha realizado con respecto al azar, la dos y la tres, se han realizado con respecto a la uno, ya que en ambas configuraciones la única variación ha sido la permuta de uno de los indicadores, la cuatro y la cinco se han realizado con respecto a la tres, que ya obtenía una ganancia con respecto a la uno, y a su vez con respecto a la realizada al azar, y finalmente se ha comparado la de la configuración cinco con respecto a la cuatro. En todas ellas hay significancia estadística, lo cual indica que los resultados obtenidos son significativos en cuanto a las variaciones realizadas y que todas ellas mejoran la solución siguiente.

	Beneficio	Beneficio Promedio por operación
Configuración al azar	---	---
Configuración 1	5.01E-03	6.2 E -04
Configuración 2	3.3E-03	1.13E-03
Configuración 3	1.618E-03	1.20E-03
Configuración 4 con respecto a 3	1.05E-04	1.27 E-05
Configuración 5 con respecto a 3	1.01E-04	5.7E-04
Configuración 5 con respecto a 4	1.20E-03	4.2E-04

Tabla 34.- Resumen del promedio y desviación típica de los datos obtenidos para todas las configuraciones. El valor mostrado es el correspondiente a P (T<=t) dos colas.

A continuación se muestra un conjunto de gráficos “bubble” o de burbujas (Figura 74 a la Figura 83) donde se enfrentan los distintos parámetros del cromosoma, con el objetivo de observar la influencia del mismo en el beneficio final obtenido. Los puntos representados poseen un tamaño variable, que es el que proporciona el vector de resultados (beneficios). Los gráficos que aparecen a continuación muestran que la distribución de resultados obtenidos no sigue una distribución uniforme, sino que algunas zonas del espacio de soluciones son más recurrentes que otras.




Figura 74.- Resultados obtenidos frente a los parámetros 1 y 2 del MACD.




Figura 75.- Resultados obtenidos frente a los parámetros 1 y 3 del MACD.




Figura 76.- Resultados obtenidos frente a los parámetros 2 y 3 del MACD.




Figura 77.- Resultados obtenidos frente a los parámetros MACDpa y MACDpb del MACD




Figura 78.- Resultados obtenidos frente a los parámetros 1 y 2 del Estocástico




Figura 79.- Resultados obtenidos frente a los parámetros 1 y 3 del Estocástico




Figura 80.- Resultados obtenidos frente a los parámetros 2 y 3 del Estocástico






Figura 81.- Resultados obtenidos frente a los parámetros estocasticopa y estocasticopb del Estocástico




Figura 82.- Resultados obtenidos frente a los parámetros "stop-loss" y "take-profit"




Figura 83.- Resultados obtenidos frente a los parámetros de Ventana MACD y Ventana del Estocástico

En todos los “gráficos de burbujas” se puede visualizar la poca variabilidad de los rendimientos obtenidos (representados éstos a través del tamaño del correspondiente círculo) en función de cualquiera de las variables que intervienen en el cálculo (parámetros del indicador técnico y tamaño de la ventana temporal).

#### 5.4.1.- Resultados conjunto 2.

En la Figura 84 se pueden ver los resultados obtenidos para el número de soluciones encontradas y las que posteriormente realizan algún tipo de operación en este conjunto. La configuración cinco tiene un 59.32% sobre el total de soluciones encontradas, seguida por la cuatro con un total de 31.39%. En cuanto a aquellas soluciones que consiguen realizar alguna operación, es decir que tienen actividad, los datos son de 56.84% y 33.43% respectivamente. El resto de resultados pertenecientes a las demás configuraciones son prácticamente insignificantes en comparación con éstos. La diferencia entre las dos mejores es de un 18% aproximadamente. En el caso del conjunto 1 el valor era de sólo un 8%, por tanto ha aumentado considerablemente. En cuanto a la desviación típica es menor en la cuarta configuración que en la quinta, más concretamente del 2.57% frente al 5.10%. Esto se debe fundamentalmente a la ampliación del espacio de búsqueda, y de ahí que se encuentre más variabilidad en las soluciones que encuentra el algoritmo. Sin embargo, se ha reducido significativamente la diferencia con respecto al conjunto anterior.




Figura 84.- Resultados para las estrategias referentes al número de soluciones encontradas y actividad.

Como se puede observar en la Figura 85, las tres primeras configuraciones no logran encontrar beneficio para este conjunto de datos. La cuatro y cinco logran un 28.66% y un 77.34% respectivamente. La mejora del uso de ventanas fijas con respecto a aquéllas en donde el algoritmo realiza su elección, es de un 49%, a favor de éstas últimas. En cuanto al número de operaciones realizadas, se aprecia que igualmente estas configuraciones llevan a cabo el mayor número de operaciones con un 21.94% y 72.59% respectivamente. En este caso la cinco casi triplica a la cuatro y esto se debe a que las ventanas que utiliza esta última son más pequeñas, y por tanto, se realizan un mayor número de operaciones.




Figura 85.- Resultados para las estrategias referentes al beneficio total y al número de operaciones realizadas

En la Figura 86 se puede apreciar el promedio de beneficio que genera cada operación. Las tres primeras generan pérdidas, mientras que la cuarta y quinta configuración generan el total de las ganancias, concretamente el 1913.68% y 1344.17% respectivamente. Este valor ha sido calculado sumando el total del beneficio calculado por operación y, a partir de ahí, se ha obtenido el porcentaje que aporta cada configuración al valor final. La diferencia a nivel de

operación no es elevada, pero ésta diferencia se acrecienta cuando consideramos el conjunto total de soluciones encontradas y las operaciones que realiza cada una de las configuraciones.




Figura 86.- Resultados para las estrategias referentes al promedio de beneficio por operación conseguido

El resumen de los datos obtenidos en todas las configuraciones analizadas se presenta en las Tabla 32 y 36.

Promedio					
	Total soluciones encontradas	Actividad	Beneficio	Número Operaciones	Beneficio Promedio x operación
Conf.-1	2.90%	2.83%	-1.42%	1.45%	-899.49%
Conf.- 2	3.10%	3.26%	-4.10%	1.69%	-1995.71%
Conf.- 3	3.29%	3.65%	-0.49%	2.33%	-262.65%
Conf.- 4	31.39%	33.43%	28.66%	21.94%	1344.17%
Conf.- 5	59.32%	56.84%	77.34%	72.59%	1913.68%

Tabla 35.- Resumen del promedio de los datos obtenidos para todas las configuraciones del conjunto 1

Desviación típica					
	Total soluciones encontradas	Actividad	Beneficio	Número Operaciones	Beneficio Promedio x operación
Conf.- 1	8.07%	5.18%	-41.40%	13.53%	-52.49%
Conf.- 2	18.88%	23.55%	0.00%	0.00%	0.00%
Conf.- 3	7.47%	13.93%	-267.46%	9.02%	-208.67%
Conf.- 4	2.57%	2.35%	10.40%	7.81%	9.92%
Conf.- 5	5.10%	3.05%	18.10%	13.47%	18.15%

Tabla 36.- Resumen de la desviación típica de los datos obtenidos para todas las configuraciones del conjunto 1

En la Tabla 37 se muestran los resultados obtenidos en el test de student para establecer la relevancia estadística de los mismos. Este estudio se muestra sólo para el beneficio total y para el beneficio promedio por operación, aunque en el resto de casos es similar. El resultado de la configuración uno se ha realizado con respecto al azar, la dos y la tres, se han realizado con

respecto a la uno, ya que en ambas configuraciones la única variación ha sido la permuta de uno de los indicadores, la cuatro y la cinco se han realizado con respecto a la tres, que ya obtenía una ganancia con respecto a la uno, y a su vez con respecto a la realizada al azar, y finalmente se ha comparado la de la configuración cinco con respecto a la cuatro. En todas ellas hay significancia estadística, lo cual indica que los resultados obtenidos son significativos en cuanto a las variaciones realizadas y que todas ellas realizan un aporte en la mejoría de la solución siguiente.

	Beneficio	Beneficio Promedio por operación
Configuración al azar	---	---
Configuración 1	4.101E-03	5.2 E -03
Configuración 2	2.439 E-02	1.648 E-02
Configuración 3	2.120 E-01	1.613 E-02
Configuración 4 con respecto a 3	1.222 E-03	2.515 E-02
Configuración 5 con respecto a 3	2.882 E-03	1.687 E-02
Configuración 5 con respecto a 4	6.768 E-03	4.612 E-02

Tabla 37.- Resumen del promedio y desviación típica de los datos obtenidos para todas las configuraciones. El valor mostrado es el correspondiente a P ( $T \leq t$ ) dos colas.

A continuación se muestra un conjunto de gráficos “bubble” o de burbujas (figuras 87 a 96) donde se enfrentan los distintos parámetros del cromosoma, con el objetivo de observar la influencia del mismo en el beneficio final obtenido. Los puntos representados poseen un tamaño variable, que es el que proporciona el vector de resultados (beneficios). Los gráficos que aparecen a continuación muestran que la distribución de resultados obtenidos no sigue una distribución uniforme.




Figura 87.- Resultados obtenidos frente a los parámetros 1 y 2 del MACD.




Figura 88.- Resultados obtenidos frente a los parámetros 1 y 3 del MACD.




Figura 89.- Resultados obtenidos frente a los parámetros 2 y 3 del MACD.




Figura 90.- Resultados obtenidos frente a los parámetros MACD<sub>pa</sub> y MACD<sub>pb</sub> del MACD




Figura 91.- Resultados obtenidos frente a los parámetros 1 y 2 del Estocástico




Figura 92.- Resultados obtenidos frente a los parámetros 1 y 3 del Estocástico




Figura 93.- Resultados obtenidos frente a los parámetros 2 y 3 del Estocástico






Figura 94.- Resultados obtenidos frente a los parámetros estocasticopa y estocasticopb del Estocástico




Figura 95.- Resultados obtenidos frente a los parámetros "stop-loss" y "take-profit"




Figura 96.- Resultados obtenidos frente a los parámetros de Ventana MACD y Ventana del Estocástico

#### 5.4.3.- Resultados conjunto 3.

En la Figura 97 se pueden ver los resultados obtenidos para el número de soluciones encontradas y las que posteriormente realizan algún tipo de operación en este conjunto. La configuración cinco tiene un 63.42% sobre el total de soluciones encontradas, seguida por la cuatro con un total de 29.44%. En cuanto a aquellas soluciones que consiguen realizar alguna operación, es decir que tienen actividad, los datos son de 62.74% y el 29.09% respectivamente. El resto de resultados pertenecientes a las demás configuraciones son muy pobres en comparación con éstos.

La diferencia entre las dos mejores es de un 33% aproximadamente. En cuanto a la desviación típica es menor en la cuarta configuración que en la quinta, más concretamente 1.88% frente a 10.45%. En este conjunto la desviación de la cuarta estrategia disminuye y se mantiene igual para la quinta. Al igual que en los conjuntos anteriores, esto se debe a la maximización del espacio de búsqueda para el segundo caso.




Figura 97.- Resultados para las estrategias referentes al número de soluciones encontradas y actividad.

Como se puede observar en la Figura 98, las tres primeras configuraciones no logran encontrar beneficio para este conjunto de datos. La cuatro y cinco logran un 71.77% y un 22.74% respectivamente. La mejora del uso de ventanas fijas con respecto a aquellas en donde el algoritmo realiza su elección es de un 49%, a favor de éstas últimas. En cuanto al número de operaciones realizadas, se aprecia que igualmente estas configuraciones llevan a cabo el mayor número de operaciones con un 16.54% y un 78.67% respectivamente. En este caso la cinco casi cuatricula a la cuatro, y esto se debe a que las ventanas que utiliza esta última son más pequeñas y por tanto se realizan un mayor número de operaciones.




Figura 98.- Resultados para las estrategias referentes al beneficio total y número de operaciones realizadas

En la Figura 99 se puede apreciar el promedio de beneficio que genera cada operación. Las tres primeras generan pérdidas, mientras que la cuarta y quinta configuración generan el total de las ganancias, concretamente el 113.26% y 189.20% respectivamente. Este valor ha sido calculado sumando el total del beneficio calculado por cada operación y, a partir de ahí, se ha calculado el porcentaje que aporta cada configuración al valor final. La diferencia a nivel de

operación no es elevada, pero esta diferencia se acrecienta cuando consideramos el conjunto total de soluciones encontradas y las operaciones que realiza cada una de las configuraciones.




Figura 99.- Resultados para las estrategias referentes al promedio de beneficio por operación conseguido

El resumen de los datos obtenidos en todas las configuraciones analizadas se presenta en las Tabla 38 y 39.

Promedio					
	Total soluciones encontradas	Actividad	Beneficio	Número Operaciones	Beneficio Promedio x operación
Conf.- 1	2.25%	2.55%	2.59%	1.20%	-54.23%
Conf.- 2	1.86%	2.29%	0.00%	1.70%	-318.40%
Conf.- 3	3.04%	3.32%	2.90%	1.88%	-29.82%
Conf.- 4	29.44%	29.09%	22.74%	16.54%	113.26%
Conf.- 5	63.42%	62.74%	71.77%	78.67%	189.20%

Tabla 38.- Resumen del promedio de los datos obtenidos para todas las configuraciones del conjunto 3

Desviación típica					
	Total soluciones encontradas	Actividad	Beneficio	Número Operaciones	Beneficio Promedio x operación
Conf.- 1	17.05%	32.88%	-60.93%	20.66%	-61.35%
Conf.- 2	27.69%	151.07%	-15.23%	0.00%	0.00%
Conf.- 3	29.75%	115.38%	-140.70%	4.07%	-111.73%
Conf.- 4	1.88%	131.74%	16.30%	5.05%	16.83%
Conf.- 5	10.45%	29.43%	14.70%	10.58%	16.25%

Tabla 39.- Resumen de la desviación típica de los datos obtenidos para todas las configuraciones del conjunto 3

En la Tabla 40 se muestran los resultados obtenidos en el test de student para establecer la relevancia estadística de los mismos. Este estudio se muestra sólo para el beneficio total y el beneficio promedio por operación, aunque en el resto de casos es similar. El resultado de la configuración uno se ha realizado con respecto al azar, la dos y la tres, se han realizado con respecto a la uno, ya que en ambas configuraciones la única variación ha sido la permuta de

uno de los indicadores, la cuatro y la cinco se han realizado con respecto a la tres, que ya obtenía una ganancia con respecto a la uno, y a su vez con respecto a la realizada al azar, y finalmente se ha comparado la de la configuración cinco con respecto a la cuatro. En todas ellas hay significancia estadística, lo cual indica que los resultados obtenidos son significativos en cuanto a las variaciones realizadas y que todas ellas aportan una mejora la solución siguiente.

	Beneficio	Beneficio Promedio por operación
Configuración al azar	---	---
Configuración 1	3.201 E-03	2.885 E -02
Configuración 2	1.360 E-02	3.475 E-02
Configuración 3	3.007 E-02	2.841 E-02
Configuración 4 con respecto a 3	7.560 E-04	5.594 E-03
Configuración 5 con respecto a 3	1.134 E-03	5.940 E-03
Configuración 5 con respecto a 4	2.185 E-03	1.251 E-02

Tabla 40.- Resumen del promedio y desviación típica de los datos obtenidos para todas las configuraciones. El valor mostrado es el correspondiente a P ( $T \leq t$ ) dos colas.

A continuación se muestra un conjunto de gráficos “bubble” o de burbujas (figuras 100 a 109) donde se enfrentan los distintos parámetros del cromosoma, con el objetivo de observar la influencia del mismo en el beneficio final obtenido. Los puntos representados poseen un tamaño variable, que es el que proporciona el vector de resultados (beneficios). Los gráficos que aparecen a continuación muestran que la distribución de resultados obtenidos no sigue una distribución uniforme, sino que algunas zonas del espacio de soluciones son más recurrentes que otras.




Figura 100.- Resultados obtenidos frente a los parámetros 1 y 2 del MACD.




Figura 101.- Resultados obtenidos frente a los parámetros 1 y 3 del MACD.




Figura 102.- Resultados obtenidos frente a los parámetros 2 y 3 del MACD.




Figura 103.- Resultados obtenidos frente a los parámetros MACD<sub>pa</sub> y MACD<sub>pb</sub> del MACD




Figura 104.- Resultados obtenidos frente a los parámetros 1 y 2 del Estocástico




Figura 105.- Resultados obtenidos frente a los parámetros 1 y 3 del Estocástico




Figura 106.- Resultados obtenidos frente a los parámetros 2 y 3 del Estocástico






Figura 107.- Resultados obtenidos frente a los parámetros estocástico<sub>pa</sub> y estocástico<sub>pb</sub> del Estocástico




Figura 108.- Resultados obtenidos frente a los parámetros "stop-loss" y "take-profit"




Figura 109.- Resultados obtenidos frente a los parámetros de Ventana MACD y Ventana del Estocástico

## 5.5.- Comparativa frente a resultados obtenidos por otras estrategias.

En este apartado se va a realizar una comparativa de la técnica empleada en este trabajo con otros tipos de estrategias. La mayor parte de los trabajos, tanto monoobjetivo como multiobjetivo sólo utilizan una única solución para operar. En algunos casos se mantiene la misma para todo un periodo, a partir de una optimización previa [Lohpetch 11] y, en otros casos se va variando conforme aparecen nuevos datos, pero finalmente sólo hay una solución que opera a pesar de que utiliza distintos objetivos para obtener la solución final [Bodas 13]. La selección de ésta puede depender de distintos factores, aunque normalmente viene determinada por el beneficio. En este trabajo se realizará una simulación de este tipo de estrategias, y para ello se escogerán las mejores soluciones para 100 experimentos, en cada conjunto de datos, y se tomará el beneficio medio resultante de aplicar esas soluciones. En la Tabla 41 podemos observar los valores encontrados.

	Conjunto 1	Conjunto 2	Conjunto 3	Media
Promedio	0.561	0.682	0.982	0.742
Desviación	0.116	0.133	0.160	0.136

Tabla 41.- Resumen de la ganancia promedio obtenida para una única solución

Por otro lado, se utilizará la estrategia denominada 'Comprar y Mantener' (*Buy & Hold*), elegida por su sencillez, así como por su extendido empleo para la evaluación de estrategias de inversión [Chen02]. Esta estrategia supone comprar un valor al principio de un periodo y mantenerlo hasta el final, momento en el que se vende. El beneficio *Buy & Hold* en este intervalo se asocia a comprar o vender al inicio del periodo y realizar la operación de cierre de

cualquiera de las dos al final del periodo. En la Tabla 42 podemos observar los valores obtenidos, tanto en el caso de compra a largo como en el de compra a corto.

	Valor inicial	Valor final	Resultado en caso de compra a largo ("pips")	Resultado en caso de compra a corto ("pips")
Conjunto 1	1.2166	1.1852	-0.0314	0.0314
Conjunto 2	1.2118	1.2880	0.0762	-0.0762
Conjunto 3	1.5803	1.5494	-0.0309	0.0309

Tabla 42.- Resumen de la ganancia obtenida para la estrategia "Buy & Hold".

Finalmente, se comparan con la solución aportada en este trabajo, donde no sólo se generan nuevas soluciones conforme los datos van cambiando en el tiempo, sino que además la operativa se produce para todas las soluciones no dominadas que conforman el frente de Pareto en cada instante. Además, recordar que los marcos temporales son seleccionados por el algoritmo evolutivo. La obtención del beneficio se calcula a partir del beneficio medio obtenido de la aplicación de dicha estrategia en un total de 100 experimentos. En la Tabla 43 se muestra el resumen de los datos obtenidos.

	Conjunto 1	Conjunto 2	Conjunto 3	Media
Promedio	18.70	36.67	46.38	33.92
Desviación	1.44	6.64	6.82	4.97

Tabla 43.- Resumen de la ganancia obtenida para el frente de Pareto

A continuación en las siguientes figuras, una para cada conjunto, se muestran los resultados obtenidos. En el eje-x se muestran números y corresponden a las siguientes estrategias: 1.- Estrategia todo el frente de Pareto, 2.- Sólo una única solución, 3.- "Buy and Hold" (compra a largo). 4.- "Buy and Hold" (Compra a corto).




Figura 110.- Beneficio obtenido por las distintas estrategias para conjunto 1




Figura 111.- Beneficio obtenido por las distintas estrategias para conjunto 2




Figura 112.- Beneficio obtenido por las distintas estrategias para conjunto 3

Como conclusión, se puede observar que los beneficios obtenidos por la solución que se aporta en éste trabajo mejoran de forma significativa los de cualquiera de las otras estrategias comparadas.

## 5.6.- Conclusiones al capítulo

Los resultados expuestos en la fase de experimentación permiten concluir lo siguiente:

1. La optimización continua de los parámetros de los indicadores técnicos MACD y Estocástico con algoritmos evolutivos, y más concretamente con el algoritmo genético

SPEA-II, mejora de manera muy significativa los resultados de las estrategias típicas y *Buy & Hold*.

2. Además, se puede apreciar que la diversidad de los valores que toma el conjunto de soluciones obtenidas por el algoritmo es muy amplio. También se observa que leves variaciones conducen a resultados completamente distintos. Este comportamiento hace que la estrategia de operar con todo el frente de Pareto sea óptima, ya que no se descartan las soluciones por un objetivo inicial, si no que es su desempeño posterior el que hace que permanezcan o que sean descartadas por la dominación de otras soluciones.
3. También se ha visto cómo los valores propuestos por la literatura para los indicadores no reflejan el comportamiento real, al menos en los resultados obtenidos por la técnica empleada en este trabajo. En cuanto a los parámetros específicos incluidos para controlar la sensibilidad de la generación de señales de operación, se ha verificado cómo intentan ampliar el rango para que la operativa logre el mayor número de operaciones posibles.
4. En cuanto al riesgo, se ha observado que hay soluciones que siguen operando a pesar de que generan pérdidas. En general, las que tienen este tipo de comportamiento se debe a que cuando son concebidas tienen poco margen de ganancia, y en cuanto que cambia el conjunto de datos se puede tornar en pérdidas. Una posibilidad sería poner algún filtro que evite que estas soluciones operen. La otra posibilidad sería cerrarlas, pero queda descartado, ya que muchas soluciones que generan beneficios finales en algún intervalo pueden producir alguna merma.
5. La dinámica del sistema, como se ha visto, es muy dependiente del propio algoritmo genético. Aunque el hecho de obtener nuevos conjuntos de soluciones cada pocos datos, hace que se minimice ésta dependencia. Además, la capacidad de explotación del algoritmo SPEA-II, junto a esta dinámica más exploratoria del propio sistema, hace que este tándem sea superior a cualquier otro como se vio en el capítulo cuatro. También este desempeño hace que se incremente el número de operaciones y por tanto, el beneficio obtenido.
6. En cuanto a la comparativa de los resultados para todos los conjuntos, se ha visto que en el conjunto de datos tres es donde se obtiene mayores beneficios. También se observa en los gráficos de burbujas, para todos los conjuntos, las distintas dependencias existentes entre los parámetros y la dispersión de los mismos.
7. En general los resultados obtenidos por el sistema multifrecuencia en comparación con el resto de estrategias es muy significativo. También hay que destacar que el empleo de ventanas no fijas mejora ampliamente los resultados obtenidos. El incluir en este trabajo medidas de tiempo de “ticks” ha supuesto un incremento significativo de los rendimientos del sistema.

## 6. Conclusiones

---

**1.- Se ha realizado una herramienta para la operativa en tiempo real en el mercado de divisas.** Ésta se basa en la optimización, a través de un algoritmo evolutivo multiobjetivo, de un conjunto de parámetros. Éstos se corresponden principalmente a tres áreas, los relacionados con los indicadores técnicos bursátiles, otros específicos del mercado (“stop-loss”, “take-profit” y “trailing-stop”) y, por último, los correspondientes a las ventanas temporales en las que se lleva a cabo la operativa. El sistema ofrece gran escalabilidad a otros posibles mercados financieros. Además, es completamente adaptable a cualquier tipo de indicadores o a la inclusión de nuevos parámetros.

**2.- El sistema genera un conjunto de expertos que opera de forma autónoma en el mercado.** Éstos son continuamente evaluados, para comprobar si existen otros que obtengan un mejor rendimiento para el conjunto de datos actual y, si esto se produce, entonces son sustituidos de forma automática. Este conjunto está formado por todo el frente de Pareto de soluciones al completo, normalmente lo conforman entre 80 y 120 soluciones diferentes. En ocasiones y para limitar el número de operaciones, se utilizan filtros que disminuyen el número de expertos con los que se opera.

**3.- La evaluación de distintos algoritmos evolutivos ha permitido observar cómo, en general, el proceso de optimización** que llevan a cabo genera buenos resultados. Para el mercado seleccionado en este trabajo ha sido el algoritmo SPEA-II el que ha obtenido mejores rendimientos. El posterior ajuste del mismo ha provocado un incremento considerable de su desempeño final.

**4.- La herramienta genera para cada experto unas condiciones diferentes de operativa en función del grado de acierto** que haya obtenido en el intervalo anterior. Esto es algo muy interesante, ya que un experto que ha generado una ganancia muy pobre o incluso pérdidas, no es eliminado, sino que se reduce la cantidad de activo que puede arriesgar, incluso pudiendo llegar a cero en algunos casos. La decisión de sustituir un experto se debe única y exclusivamente al hecho de ser dominado por otro. Este comportamiento permite limitar el riesgo tanto a nivel local como global para toda la operativa. Esto es uno de los objetivos principales de cualquier sistema de “trading”.

**5.- Se ha observado cómo el maximizar el número de operaciones realizadas mejora los beneficios obtenidos.** Evidentemente el coste total de las transacciones aumenta, pero la ganancia obtenida supera en mucho este coste. Además, al realizarse un gran número de operaciones y resolverse en un plazo muy corto de tiempo, los gastos asociados al interés que genera la obtención del capital se ven reducidos a prácticamente cero. También se observó que en general el sistema tendía a realizar los beneficios de manera rápida.

**6.- Se ha validado la herramienta mediante el empleo de datos reales.** Se han realizado dos tipos de experimentos. En el primero de ellos se comparan los resultados obtenidos por la solución implementada frente a aquellas estrategias que utilizan valores estándar para sus parámetros [Elder93]. Se ha podido observar cómo conforme se aumenta el número de grados de libertad en el algoritmo evolutivo multiobjetivo, los resultados mejoran considerablemente. En el segundo de los experimentos, el objetivo es comparar el beneficio de la técnica desarrollada con estrategias bursátiles habituales como “buy and hold”, o aquellas que utilizan una única solución del frente de Pareto [Lohpetch11]. En este

último caso los resultados obtenidos por el sistema multifrecuencia en comparación con el resto de estrategias conllevan una mejora muy significativa.

**7.- El trabajar con datos “tick” a “tick”** ha supuesto un importante incremento del rendimiento del sistema.

**8.- Los expertos encontrados por el algoritmo evolutivo no muestran ningún rasgo identificativo**, más allá de aquellos elementos que son encontrados en el mismo intervalo de tiempo. Esto indica que son múltiples las soluciones que permiten la generación de beneficios. Un hecho también muy relevante es el de que las ventanas temporales formen parte de la solución, como así se ha observado en los resultados finales.

**9.- El trabajo aquí desarrollado abre una línea de investigación** en cuanto al estudio de otros tipos de indicadores o la selección de nuevos parámetros para los mismos. También permite trabajar con nuevos mercados, sobre todo aquéllos que permitan apalancamiento.





## 7. Publicaciones

---

**Publicaciones en congresos internacionales**

1. Bodas-Sagi, D. J., Fernández, P., Hidalgo, J. I., Soltero, F. J., Fernández F. , A Technique for the Optimization of the Parameters of Technical Indicators with Multi-Objective Evolutionary Algorithms. *IEEE Congress on Evolutionary Computation 2012*, accepted paper. 2012.
2. Soltero, F. J., Bodas-Sagi, D. J., Fernández, P., Hidalgo, J. F. Fernández, Optimization of Technical Indicators in real time with Multiobjective Evolutionary Algorithms. In: *Proceedings of the 12th Annual Conference on Genetic and Evolutionary Computation. GECCO'12*. Philadelphia, USA. 2012.
3. Fernández-Blanco P., Bodas-Sagi D.J., Soltero F., Hidalgo J.I. Technical Market Indicators Optimization using Evolutionary Algorithms. In: *Proceedings of the 10th Annual Conference on Genetic and Evolutionary Computation Conference (GECCO'08)*. Atlanta (USA). 2008.
4. Bodas-Sagi, D. J., Fernández, P., Hidalgo, J. I., Soltero, F. J., Risco-Martín, J. L. Multi-objective optimization of technical market indicators. In: *Proceedings of the 11th Annual Conference on Genetic and Evolutionary Computation. GECCO'09*. pp. 1999 – 2004. Late Breaking Paper. 2009.

**Publicaciones en congresos nacionales**

5. Bodas-Sagi, D. J., Fernández, P., Hidalgo, J. I. and Soltero, F. J. Optimización de Indicadores Técnicos con Algoritmos Evolutivos. *VI Congreso Español sobre Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB'09)*. Málaga. 2009.

**Publicaciones en revistas**

6. Fernández P., Bodas D., Soltero F. J., Hidalgo I. Optimización de Indicadores Técnicos Bursátiles mediante el uso de Algoritmos Evolutivos. *Anales de Ingeniería Técnica en Informática de Sistemas 2008*. Vol. II. Felipe II Libros. 2008.
7. Fernández P., Bodas D., Soltero F. J., Hidalgo I. Aplicaciones de los Algoritmos Evolutivos en Economía. *Anales de Ingeniería Técnica en Informática de Sistemas 2007*. Felipe II Libros. 2007.
8. Bodas-Sagi, D. J., Fernández, P., Hidalgo, J. I. and Soltero, F. J. A Parallel Evolutionary Algorithm for Technical Market Indicator Optimization. *Natural Computing*. 2012.

## 8. Bibliografía

---

- [Aarts89] Aarts, E.H.L. y Korst, J. Simulated Annealing and Boltzmann Machines. John Wiley, Chichester, UK, primera edición, 1989.
- [Adeli94] Adeli H., Cheng N.T. Augmented lagrangian genetic algorithm for structural optimization. *Journal of Aerospace Engineering*, 7(1):104–118–, 1994. doi: 10.1061/(ASCE)0893-1321(1994)7:1(104).
- [Ahmed05] Ahmed, P., Nanda. Performance of Enhanced Index and Quantitative Equity Funds. *Financial Review*, 40 (4), 459-479. 2005.
- [Aine08] Aine S., Kumar R., Chakrabarti P.. Adaptive parameter control of evolutionary algorithms to improve quality-time trade-off. *Applied Soft Computing*, 9(2):527–540, 2009. ISSN 1568-4946. doi: 10.1016/j.asoc.2008.07.001.
- [Alander00] Alander J. “Indexed bibliography of genetic algorithms in economics”. Report 94-1-ECO. University of Vaasa. Department of Information Technology and Production Economics. 2000.
- [Allen99] Allen F., Karjalainen R. Using Genetic Algorithms to Find Technical Trading Rules. *Journal of Financial Economics*. Elsevier 51.(2) pp. 245-271. 1999.
- [Alexander61] Alexander, S. Price movements in speculative markets: trends or random walks? *Industrial Management Review*, 2 (2), 7–26. 1961.
- [Anderson96] Anderson, M.B. y Lawrence, W.R. Launch conditions and aerodynamic data extraction by an elitist pareto genetic algorithm. En *AIAA Atmospheric Flight Mechanics Conference*, San Diego, California. AIAA Paper 96-3361.
- [Andersson01] Andersson, J. Multiobjective Optimization in Engineering Design. Applications to Fluid Power systems. Tesis doctoral. Institute of Technology. Universidad de Linköpings, Suecia, 2001.
- [Andrés96] Andrés Toro, B., Modelización, optimización y control de un proceso cervicero Industrial, Tesis doctoral, Universidad Complutense de Madrid, 1996.
- [Andrés97] Andrés Toro, B., Girón Sierra, J.M. Fernández-Conde, C., Peinado, J.M. y García-Ochoa, F. A kinetic model for beer fermentation under industrial operational conditions, pág. 203-208. *Proc. IMACS/IFAC 2th. Int. Symp.. Mathematical Modelling and Simulation in Agricultural and Bio-Industries*, Budapest, Hungría, 1997.
- [Andrés98a] Andrés Toro, B., Girón Sierra, J.M., López Orozco, J.A., Fernández Conde, C., Fernández Blanco, P. A fast Genetic Optimization for Batch Fermentation Processes. 7th International Conference on Computer Application in Biotechnology, pág. 61-66, Osaka (Japón), junio 1998.

- [Andrés98b] Andrés Toro, B., Girón Sierra, J.M., López Orozco, J.A., Peinado, J.M. A kinetic model for beer production under industrial operational condition. *Mathematics and Computers in Simulation*, vol.48 nº1, pág. 65-74, nov.1998.
- [Andrés98c] Andrés Toro, B., Girón Sierra, J.M., López Orozco, J.A., Fernández Blanco, P. Metodología de modelación y optimización de procesos basada en algoritmos genéticos. XIX jornadas de automática, pág 211-215, Madrid, 16-18 sept. 1998.
- [Andrés99] Andrés Toro, B., Girón Sierra, J.M., López Orozco, J.A., Álvarez Ruiz, J., Fernández Blanco, P. A Genetic Optimization Method for Dynamic Processes. *Proceedings of the 14th World Congress. IFAC*, vol. C, pág. 373-377. Editorial Pergamon, Beijing, R.P.China, 5-9 jul99..
- [Andrés00a] Andrés Toro, B., Girón Sierra, J.M., Fernández Blanco, P. de la Cruz, J.M., López Orozco, J.A. Application of Genetic Algorithms to Determine Parameters Process Models. *International Symposium on Advanced Control of Chemical Processes. IFAC. vol. I (Control Design)*, pág.455-460, 14-16 junio 2000, Pisa (Italia).
- [Andrés00b] Andrés Toro, B., Girón Sierra, J.M., Fernández Blanco, P. de la Cruz, J.M., López Orozco, J.A. Parallel Genetic Algorithms with a continuity operator that allows for knowledge inclusion. *Congress on Evolutionary Computation del IEEE*, La Jolla, California. Julio, 2000.
- [Andrés02a] Andrés Toro, B., Girón Sierra, J.M., Fernández Blanco, P. de la Cruz, J.M., López Orozco, J.A. Aplicación del diseño de control multiobjetivo y multivariable, con algoritmos genéticos, al proceso de la fermentación de la cerveza. *Alimentación: equipos y tecnología*, nº 168, pág. 49-57, mayo 2002.
- [Andrés02b] Andrés Toro, B., Girón Sierra, J.M., Fernández Blanco, P. de la Cruz, J.M., López Orozco, J.A. Multiobjectives Optimization of Dynamic Processes by Evolutionary Methods. 15<sup>th</sup> triennial world congress of the IFAC, 21-26 julio 2002, Barcelona, Elsevier Science.
- [Andreu04] Andreu Corbatón J., Ceballos Hornero D. Aplicación del método Fuzzy Delphi a la predicción bursátil. In *XI Congress of International Association for Fuzzy-set management and Economy. University Mediterranea of Reggio Calabria. Italia 2004*.
- [Antonisse89] Antonisse, J. A New Interpretation of the Schema Notation that Overturns the Binary Encoding Constraint. En [Schaffer89], pág. 86-91.
- [Aragonés94] Aragonés J. R. Mascareñas J. La eficiencia y el equilibrio en los mercados de capital. *Análisis Financiero*. Nº 64. Pgs. 76-89. 1994.

- [Arifovic94] Arifovic J., Genetic Algorithm Learning and the Cobweb Model , Journal of Economic Dynamics and Control, 18 (1), pp. 3-28. , January 1994.
- [Arifovic00] Arifovic J., Evolutionary Algorithms in Macroeconomic Models. Macroeconomic Dynamics, Cambridge University Press, 4(3), pags. 373-414, September 2000.
- [Bachelier00] Bachelier, L. (1900), "Théorie de la Spéculation" Annales Scientifiques de l'Ecole Normale Supérieure Sér., 3(17), 21–86.
- [Bäck93] Bäck, T. Optimal mutation rates in genetic search, en Forrest93, pág. 2-8.
- [Bäck94] Bäck, T. Selective pressure in evolutionary algorithms: A characterization of selection mechanisms. In Proceedings of the First IEEE Conference on Evolutionary Computation, pages 57–62. IEEE Press, 1994
- [Bäck95] Bäck T. Generalized convergence models for tournament- and ( $\mu$ ,  $\lambda$ ) selection. In Proceedings of the 6th International Conference on Genetic Algorithms, pages 2–8, San Francisco, CA, USA, 1995. Morgan Kaufmann Publishers Inc. ISBN 1-55860-370-0.
- [Bäck96] Bäck, T. Evolutionary Algorithms in Theory and Practice. New York, etc: Oxford University Press.
- [Bäck97] Bäck, T., Hammel, U. Y Schwefel, H.P. Evolutionary computation: Comments on the history and current state. IEEE Transactions on Evolutionary Computation 1(1), 3-17.
- [Baker85] J. E. Baker. Adaptive selection methods for genetic algorithms. In Proceedings of the 1st International Conference on Genetic Algorithms, pages 101–111, Hillsdale, NJ, USA, 1985. L. Erlbaum Associates Inc. ISBN 0-8058-0426-9.
- [Baker87] Baker, J. E. Reducing bias and inefficiency in the selection algorithm. In Proceedings of the Second International Conference on Genetic Algorithms on Genetic algorithms and their application, pages 14–21, Hillsdale, NJ, USA, 1987. L. Erlbaum Associates Inc. ISBN 0-8058-0158-8
- [Batey61] Batey, E.H., Courts, H.R., Hannah, K.W., Dynamic approach to gas-pipeline analysis. Oil Gas Journal, vol. 59, pág. 65-78, 1961.
- [Bean92] Bean J., Ben Hadj-Alouane A. A dual genetic algorithm for bounded integer programs. Technical Report 9253, 1992.
- [Bebczuk10] Bebczuk R. et al. Progresos en finanzas. Capitulo IV. 1a ed. - Buenos Aires : Temas Grupo Editorial, 2010. ISBN 978-950-9445-87-1
- [Beek02] Beek, D.A., Ham, A. y Rooda, J.E. Modelling and Control of Process Industry Batch Production Systems. 15<sup>th</sup> triennial Worl Congress, Barcelona, 2002.

- [Bellman57] Bellman, Richard. Dynamic Programming. Princeton University Press, Princeton, pág. 83. Nueva Jersey. 1957.
- [Bellman61] Bellman, Richard. Adaptive Control Processes: A Guided Tour. Princeton, New Jersey. Princeton University Press, 1961.
- [Belur97] Belur S. V. CORE: Constrained Optimization by Random Evolution, pages: 280–286. Stanford Bookstore, 1997.
- [Ben97] Ben Hadj-Alouane A., Bean J. A genetic algorithm for the multiple-choice integer program. Operations Research, 45(1):92–101, 1997.
- [Bertoni93] Bertoni, A. Dorigo, M.: Implicit Parallelism in Genetic Algorithms. Artificial Intelligence (61) 2, pág. 307-314, 1993.
- [Besada02] Besada-Portas, E. López-Orozco, J.A., Andrés-Toro. B. A versatile toolbox for solving industrial problems with several evolutionary techniques, en Evolutionary Methods for Design, Optimization and Control, ed. International Centre for Numerical Methods in Engineering (CIMNE), Barcelona, Marzo 2002.
- [Bessembinder95] Bessembinder, H. y Chan, K. The profitability of technical trading rules in the asian stock markets, Pacific-Basic Finance Journal , Elsevier 3 (2-3), 257–284. 1995.
- [Bilous56] Bilous, O. and Amundson, N. R. Chemical Reactor Stability and Sensitivity. Part II, AIChE Journal, 2(1), 117–126, 1956.
- [Blickle95] Blickle, T. y Thiele, L. A mathematical analysis of tournament selection, en [Eshelman95], pág. 9-16.
- [Blickle96] Blickle T. y Thiele L. A comparison of selection schemes used in evolutionary algorithms. Evolutionary Computation, 4(4):361–394, 1996.
- [Bodas09] Bodas-Sagi, D. J., Fernández, P., Hidalgo, J. I., Soltero, F. J., Risco-Martín, J. L. Multi-objective optimization of technical market indicators. In Proceedings of the 11th Annual Conference on Genetic and Evolutionary Computation. GECCO'09. pp. 1999 – 2004. 2009.
- [Bodas12] Bodas-Sagi, D. J., Fernández, P., Hidalgo, J. I., Soltero, F. J. A Technique for the Optimization of the Parameters of Technical Indicators with Multi-Objective Evolutionary Algorithms. IEEE Congress on Evolutionary Computation 2012..
- [Bodas13] Bodas, D. J. “Una técnica para la optimización de los parámetros de indicadores técnicos bursátiles mediante algoritmos evolutivos multi-objetivo”. Tesis Doctoral, Universidad Complutense de Madrid (España), 2013.



- [Box70] Box G., Jenkins G. Time series analysis: Forecasting and control, San Francisco Holden-Day. 1970.
- [Bojkov94] Bojkov, B., y Luus, R. Application of iterative dynamic programming to time optimal control, Trans. IChemE, 72, part A, pág. 72-80, 1994.
- [Bollerslev86] Bollerslev T. Generalized Autoregressive Conditional Heteroskedasticity Journal of Econometrics. Elsevier, 31 (3). pp: 307 – 28. 1986.
- [Boyd91] Boyd, S.P. y Barrat, C.H. Linear Controller Design. Limit of Performance. Prentice Hall, New Jersey, 1991.
- [Box57] Box, G.E.P., Evolutionary Operation: A Method for Increasing Industrial Productivity, Applied Statistics, vol.6, nº 2, pág. 81-101, 1957.
- [Box69] Box G.E. P., Cox, D. R. An analysis of transformations. Journal of the Royal Statistical Society, Series B 26: 211–246. 1964.
- [Box70] Box G., Jenkins G. Time series analysis: Forecasting and control, San Francisco Holden-Day. 1970.
- [Bradwell99] Bradwell, R., Brown, K. Parallel Asynchronous Memetic Algorithms. Proceedings of the GECCO99. Orlando (Florida), jul 99, pág. 157-159.
- [Brassard97] Brassard, G., Bratley, P. Fundamentos de Algoritmos. Prentice Hall Inc. 1997.
- [Brindle81] Brindle A. Genetic algorithms for function optimization. PhD thesis, Dept. of Computing Science, University of Alberta, Edmonton, 1981.
- [Brock92] Brock, W., Lakonishhock, J. y LeBaron, B. Simple technical trading rules and the stochastic of stock returns, Journal of Finance, 47 (5), 1731–1764. 1992.
- [Buriol04] Buriol, L.; Franca, P. 2004. A new memetic algorithm for the asymmetric traveling salesman problem. Journal of Heuristics. 10 (5): 483-506.
- [Brown40] Brown, W. A. (1940): Tite international Cold Standard Reinwrp'-eted, NEER, Nueva York.
- [Campbell97] Campbell, J. Y., Lo, A. W. y MacKinlay, A. C. The Econometrics of Financial Markets, Princeton, New Jersey: Princeton University Press. 1997.
- [Cantú97] Cantú-Paz, E. A Survey of Parallel Genetic Algorithm. IlliGAL Report nº 97003. University of Illinois at Urbana-Champaign. 1997.
- [Cantú99a] Cantú Paz, Erick. Parallel Genetic Algorithms with Distributed Panmitic Populations. IlliGAL Report nº 99006, enero 1999.
- [Cantú99b] Cantú-Paz, Erick. Designing Efficient and accurate Parallel Genetic Algorithms. IlliGAL Report nº 99017, julio 1999.

- [Carroll61] Carroll C. W. The created response surface technique for optimizing nonlinear, restrained systems. *Operations Research*, 9:169–185, 1961.
- [Castejon07] C. Castejon, G. Carbone, J. G. Prada, and M. Ceccarelli. A Multi-Objective Optimization Design for a 4R Service Robot. *International Journal of Mechanics and Control*, 2007, Vol.08, N.02, pp..3-8, 2007.
- [Chankong83] Chankong, V. y Haimes, Y.Y. *Multiobjective Decision Making Theory and Methodology*. Elsevier Science Publishing Co., Inc., New York, 1983.
- [Chen90] Chen, C., y Hwang, C. Optimal control computation for differential-algebraic process systems with general constraints. *Chem. Eng. Comm.*, nº 97, pág. 9-26, 1990.
- [Chen96] Cheng R., Gen M., Tsujimura Y. A tutorial survey of job-shop scheduling problems using genetic algorithms—i. representation. *Computers & Industrial Engineering* , 30(4):983 – 997, 1996. ISSN 0360-8352. doi: 10.1016/0360-8352(96)00047-2.
- [Chen98] Chen, S. y S. Rajan. Improving the efficiency of genetic algorithms for frame designs. *Engineering Optimization*, 30(3):281 – 307–, 1998. ISSN 0305-215X.
- [Chen02] Chen, S. H. *Evolutionary Computation in Economics and Finance*. Physica-Verlag, Heidelberg, 2002.
- [Cheung97] Cheung, B.K.S., Langevin, A. Y Delmaire, H. Coupling Genetic Algorithm with a Grid Search Method to Solve Mixed Integer Nonlinear Programming Problems. *Computers Math. Applic.*, 34(12): pág. 13-23, 1997.
- [Chiarella92] Chiarella, C. The dynamics of speculative behaviour, *Annals of Operations Research*, 37 (1), 101–124. 1992.
- [Christofides01] Christofides, P.D. Control of Nonlinear Distributed Process Systems: Recent Developments and Challenges. *AIChE Journal*, vol.47, nº3, marzo 2001.
- [Cieniawski95] Cieniawski, S.E., Eheart, J.W. y Ranjithan, S. Using genetic algorithms to solve a multiobjective groundwater monitoring problem. *Water Resources Research* 31(2), pág. 399-409, 1995.
- [Clark88] Clark, N., juma, C. Evolutionary theories in economic thought. G.Dosi, Ch. Freeman, R. Nelson, G. Silverberg y L Soete (Eds.). *Technical Changeand Economic Theory*, cap. 9: 197-218. Pinter Publishers Limited. London. 1988.
- [Clarke64] Clarke, G. y Wright, J.W. Scheduling of Vehicles from a Central Depot to a Number of Delivery Points. *Operations Research*, vol. 12, pág. 568-581, 1964.
- [Coello94] Coello Coello, C.A. Coello, Carlos A. y Yáñez López, Araceli, *Actas del VIII Simposio Internacional en Aplicaciones de Informática*, Antofagasta, Chile, pp. 151-157, 21 al 25 de noviembre de 1994.

- [Coello99] Coello Coello, C.A. A comprehensive survey of evolutionary-based multiobjective optimization. Knowledge and Information Systems.
- [Coello99a] Coello Coello C. A. Treating constraints as objectives for single-objective evolutionary optimization. Engineering Optimization, 32:275–308, 1999.
- [Coello00] Coello Coello, C.A. An Updated Survey of GA-Based Multiobjective Optimization Techniques. ACM Computing Surveys, vol. 32, nº 2, junio 2000, pág. 109-143.
- [Cohon78] Cohon, J.L. Multicriteria programming and Planning. New York. Academic Press, 1978.
- [Cohon85] Cohon, J.L. Multicriteria programming: brief review and application. In J.S. Gero Ed., Design Optimization, pág 163-191. Orlando, Florida: Academic Press, 1985.
- [Cook98] Cook, W.J. Cunningham, W.H., Pulleyblank, W.R. y Schrijver, A. Combinatorial Optimization. John Wiley, Chichester, UK, 1998.
- [Corne00] Corne, D. W., Knowles, J.D. and Oates, M.J. (2000). The pareto-Envelope based Selection Algorithm for Multiobjective Optimisation, in Schoenauer, M., Deb, K., Rudolph, G., Yao, X., Lutton, E., Merelo, JJ. and Schwefel, H-P. (eds.), Parallel-Problem Solving from Nature - PPSN VI, Springer Lecture Notes in Computer Science, pp. 869-878.
- [Courant43] Courant R. Variational methods for the solution of problems of equilibrium and vibrations. 1943.
- [Cowles60] Cowles, A. y H. E. Jones. "A Revision of Previous Conclusions Regarding Stock Price Behavior". Econometrica, 28, 909-915. 1960.
- [Cruz03] Cruz, J.M. de la, Andrés-Toro, B. de, Herrán, A., Besada-Porta, E. Fernández-Blanco, P. Multiobjective Optimization of the Transport in Oil Pipelines Networks. ETFA2003, IEEE Conference on Emerging Technologies and Factory Automation Proceedings, pág.566-573, Lisboa, 16-19 septiembre 2003.
- [Cruz04] Cruz, J.M. de la, Risco, J.L., Herrán, A., Fernández-Blanco, P. Multiobjective Optimization of the Transport in Oil Pipelines Networks. Conference on Evolutionary Computation, CEC2004, IEEE, Oregon, EEUU, junio 2004.
- [Cunha97] Cunha, A. Oliviera, G.P. y Covas, J. Use of genetic algorithms in multicriteria optimization to solve industrial problems. En T. Bäck (Ed.), Proceedings of the seventh International Conference on Genetic Algorithms. San Francisco, California, pág. 682-688, Morgan Kaufmann, 1997.

- [Cuthrell89] Cuthrell, J.E., y Biegler, L.T. Simultaneous optimization and solution methods for batch reactor control profiles. *Comput. Chem. Eng.*, vol. 13, pág. 49-62, 1989.
- [Cvetkovic00] Cvetkovic, D. Evolutionary Multi-Objective Decision Support Systems for Conceptual Design. Tesis doctoral. University of Plymouth, julio 2000.
- [Dadebo95] Dadebo, S.A., y McAuley, K.B. A simultaneous iterative solution technique for time-optimal control using dynamic programming, *Ind. Eng. Chem. Res.*, vol. 34, pág. 2077-2083, 1995.
- [Darwin66] Darwin, C. The origin of species by means of natural selection, or the preservation of favoured races in the struggle for life. J. Murray, London, 1866.
- [Davis89] Davis, L. Adapting operator probabilities in genetic algorithms. In *Proceedings of the third international conference on Genetic algorithms*, pages 61–69, San Francisco, CA, USA, 1989. Morgan Kaufmann Publishers Inc. ISBN 1-55860-006-3.
- [Davis91] Davis. *Handbook of Genetic Algorithms*. Van Nostrand Reinhold, 1991.
- [Deb89a] Deb, K. Genetic Algorithms in Multimodal Function Optimization. Master Thesis and tcga report n°89002, Tucaloosa, Universidad de Alabama, 1989.
- [Deb89b] Deb, K. y Goldberg, D.E. An Investigation of Niche and Species Formation in Genetic Function Optimization, en *Proceedings of the Third International Conference on Genetic Algorithms*, pág. 42-50, 1989.
- [Deb90] Deb, K. Joshi, D. y Anand, A.. Real-coded evolutionary algorithms with parent-centric recombination. In *Evolutionary Computation, 2002. CEC '02. Proceedings of the 2002 Congress on*, volume 1, pages 61 –66, may 2002. doi: 10.1109/CEC.2002.1006210.
- [Deb94] Deb, K y Agrawal R.. Simulated binary crossover for continuous search space. Technical report, 1994.
- [Deb96] Deb, K. y Goyal, M.. A combined genetic adaptive search (geneas) for engineering design. *Computer Science and Informatics*, 26:30–45, 1996.
- [Deb98] Deb, K. Multi-objective genetic algorithms: problem difficulties and construction of test functions. Technical Report N° CI-49/98, Department of Computer Science/XI, University of Dortmund, Germany, 1998.
- [Deb99a] Deb, K. Evolutionary algorithms for multi-criterion optimization in engineering design, en *Proceedings of Evolutionary Algorithms in Engineering and Computer Science (EUROGEN'99)*, 1999.

- [Deb99b] Deb, K. y Beyer, H.G. Self-adaptive genetic algorithms with simulated binary crossover. Technical Report CI-61/99, Department of computer Science, Universidad de Dortmund, Alemania, 1999.
- [Deb01] Deb, K. y Beyer, H.-g.. Self-adaptive genetic algorithms with simulated binary crossover. *Evol. Comput.*, 9:197–221, June 2001. ISSN 1063-6560. doi:10.1162/106365601750190406.
- [Deb01b] Deb, K. Multi-objective optimization using evolutionary algorithms. New York: Wiley, 2001.
- [Deb02] Deb, K.; Agrawal, S.; Pratab, A.; Meyarivan, T. 2000. A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II, In *Proceedings of the Parallel Problem Solving from Nature VI Conference*, Marc Schoenauer, Kalyanmoy Deb, Günter Rudolph, Xin Yao, Evelyne Lutton, J. J. Merelo and Hans-Paul Schwefel (editors), 849-858. Springer.
- [DeJong75] De Jong, K. A. An analysis of the behaviour of a class of genetic adaptive systems. *Dissertation Abstracts International*, 1975.
- [DeJong91] De Jong, K. Are Genetic Algorithms Function Optimizers? En *PPSN 2*, (Männer y Manderick eds.) North Holland, pág. 3-14, 1991.
- [DeJong92] De Jong, K. y J. Sarma. Generation gaps revisited. In *Foundations of Genetic Algorithms*. Morgan Kaufmann, 1992.
- [Despontin83] Despontin, M., Moscarola, J., Spronk, J. A user-Oriented Listing of Multiple Criteria Decision Methods. *Revue Belge de Statistique, d'Informatique et de Recherche Operationnelle* 23(4), pág.4-110, 1983.
- [Dias02] DIAS, A.; DE VASCONCELOS J. (March, 2002). "Multiobjective Genetic Algorithms Applied to Solve Optimization Problems". *IEE Transactions on Magnetism*, Vol. 38, N° 2.
- [Díaz96] Díaz, Adenso, Glover, F., Ghaziri, H.M., González, J.L., Laguna, M., Moscato, P. y Tseng, F.T. Optimización heurística y redes neuronales. Ed. Paraninfo, 1996.
- [Dorigo92] Dorigo, M. Optimization, Learning and Natural Algorithms. Tesis doctoral, Politecnico di Milano, 1992.
- [Dorigo96] Dorigo M., Maniezzo, V. y Colorni, A. The Ant System: Optimization by a Colony of Cooperating Agents. *IEEE Transactions on Systems, Man, and Cybernetics-Part B*, 26(1), pág.29-41, 1996.
- [Dorsey98] Dorsey R. E., Sexton R. S., The use of parsimonious neural networks for forecasting financial time series. *Journal of Computational Intelligence in Finance*, 6 (1). pp. 24-31. 1998.

- [Drezner03] Drezner, Z. 2003. A new genetic algorithm for the quadratic assignment problem. *Inform Journal on Computing* 15 (3): 320-330
- [Durand89] Durand, M. Parallel Simulated Annealing: Accuracy vs. Speed in placement. *IEEE Design&Test of Computers*, 1989.
- [Durillo09] J.J. Durillo, A.J. Nebro, and E. Alba. The jMetal framework for multi-objective optimization: Design and architecture. In *CEC 2010*, pages 4138 {4325, Barcelona, Spain, July 2010.
- [Durillo10] J.J. Durillo, A.J. Nebro, F. Luna, and E. Alba. On the select of the steady-state selection scheme in multi-objective genetic algorithms. In *5th International Conference, EMO 2009*, volume 5467 of *Lecture Notes in Computer Science*, pages 183{197, Nantes, France, April 2009. Springer Berlin /Heidelberg.
- [Edgar88] Edgar, T.F. y Himmelblau, D.M. Optimization of chemical processes. McGraw-Hill, New York, 1988.
- [Eiben95] Eiben A. , C. van Kemenade, y J. Kok. Orgy in the computer: Multi-parent reproduction in genetic algorithms. 1995.
- [Einstein05] Einstein, A. "Über die von der molekularkinetischen Theorie der Wärme geforderte Bewegung von in ruhenden Flüssigkeiten suspendierten Teilchen," *Annalen der Physik*, 322(8), 549–560. Einstein, A. (1905), "Über die von der molekularkinetischen Theorie der Wärme geforderte Bewegung von in ruhenden Flüssigkeiten suspendierten Teilchen," *Annalen der Physik*, 322(8), 549–560.
- [Eklund03] Eklund S. E., Time Series Forecasting using Massively Parallel Genetic Programming. *IPDPS'03: Proceedings of the International Parallel and Distributed Processing Symposium*. IEEE Computer Society. pp. 143 - 147. USA 2003.
- [Engle82] Engle R.F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*. 50 (4). pp. 987-1007. 1982.
- [Eshelman93] Eshelman, L.J. and Schaffer J.D. Real-Coded Genetic Algorithms and Interval-Schemata, *Foundations of Genetic Algorithms* 2, pp. 187-202 (1993).
- [Eshelman95] Eshelman, L.J., *Proceedings of the sixth international conference on genetic algorithms*. Morgan Kaufmann, 1995.
- [Esteban02] Estebán San Román, Segundo. Modelado y control del movimiento longitudinal de un ferry de alta velocidad. Tesis doctoral, Universidad Complutense de Madrid, 2002.

- [Everson02] Everson, R.M., Fieldsend, J.E., Singh, S., Full Elite Sets for Multi-objective Optimisation. Proceedings of the fifth international Conference on adaptive computing design and manufacture (ACDM 2002), 2002.
- [Fama66] Fama, E. y Blume, M. Filter rules and stock market trading,. Journal of Business, Part 2: Supplement on Security Pricing, 39 (1), pp. 226–241. 1966.
- [Fama70] Fama, E. F. Efficient capital markets: a review of theory and empirical work. Journal of Finance. 25:383–417, 1970.
- [Fama88] Fama, E. F. y French, K. R. Permanent and temporary components of stock prices, Journal of Political Economy, 96 (2), pp. 246–273. 1988.
- [Fama91] Fama, E. F. Efficient capital markets: II, Journal of Finance, 46 (5), pp. 575 – 1617. 1991.
- [Fast96] 126m Long Spanish Fast Ferry Launched. Fast Ferries, pág. 19-20, sept. 1996.
- [Fernández07] Fernández Blanco P., Soltero Domingo F. J., Bodas Sagi D. J., Hidalgo J. I. Aplicaciones de los Algoritmos Evolutivos en Economía. Anales de Ingeniería Técnica Informática de Sistemas. nº 1, ISBN 978-84-935511-2-4, pp. 57-67. Madrid 2007.
- [Fernández08] Fernández-Blanco, P., Bodas-Sagi, D. J., Soltero, F. J., and Hidalgo, J. I. Technical market indicators optimization using evolutionary algorithms. In Keijzer (Ed.) Proceedings of the Genetic and Evolutionary Computation Conference (GECCO'2008). New York 2008. pp. 1851-1858. 2008.
- [Fernandez11] Fernández Díaz, Andrés. Política monetaria: fundamentos y estrategias. Editorial Paraninfo, 2011. ISBN 8497328922.
- [Fernández99] Fernández Rodríguez, F., Sosvilla Rivero, S. y Andrada Félix, J. Análisis técnico en la bolsa de madrid, Moneda y Crédito, 213, pp. 11–37. 1999.
- [Fiacco66] Fiacco A. V., McCormick G. P. Extensions of sumt for nonlinear programming: Equality constraints and extrapolation extensions of sumt for nonlinear programming: Equality constraints and extrapolation. Management Science, 12(11):816–828, 1966. doi: 10.1287/mnsc.12.11.816.
- [Fisher30] Fisher, I. The Theory of interest. The Macmillan Company. 1930. ISBN13 978-0879918644.
- [Fogarty89] Fogarty, T.C. Varying the Probability of Mutation in the Genetic Algorithms, en [Schaffer89], pág. 104-109, 1989.
- [Fogel62] Fogel, L.J. Autonomous automata. Industrial Research 4, pág. 14-19, 1962.
- [Fogel64] Fogel, L.J. On the Organization of the Intellect. Tesis doctoral. UCLA, 1964.

- [Fogel66] Fogel, L.J., Owens, A.J. y Walsh, M.J. Artificial Intelligence Through Simulated Evolution. John Wiley, New York, 1966.
- [Fonseca93] Fonseca, C.M. y Fleming, P.J. Genetic algorithms for multiobjective optimization: Formulation, discussion and generalization. En S- Forrest (Ed.), Proceedings of the Fifth International Conference on Genetic Algorithms, San Mateo, California, págs. 416-423, Morgan Kaufmann, 1993.
- [Fonseca95a] Fonseca, C.M., y Fleming, P.J. An overview of evolutionary algorithms in multiobjective optimization. *Evolutionary Computation* 3(1), págs. 1-16, 1995.
- [Fonseca95b] Fonseca, C.M., y Fleming, P.J. Multiobjective Genetic Algorithms Made Easy: Selection, Sharing and Mate Restriction, en Proceedings of the First International Conference on Genetic Algorithms in Engineering Systems, Innovations and Applications, GALESIA, págs. 45-52, University of Sheffield, sept.1995.
- [Fonseca96] Fonseca, C.M., y Fleming, P.J. Non-Linear System Identification with Multiobjective Genetic Algorithms. *Proc. IFAC 13th. World Congress* 2a-06, 2, 187, 1996.
- [Fonseca98a] Fonseca, C.M. y Fleming, P.J. Multiobjective Optimization and Multiple Constraint Handling with Evolutionary Algorithm-Part I: A unified formulation. *IEEE Transactions on Systems, Man, and Cybernetics. Part A: Systems and Humans*. vol. 28, nº 1, págs. 26-37 enero 1998.
- [Fonseca98b] Fonseca, C.M. y Fleming, P.J. Multiobjective Optimization and Multiple Constraint Handling with Evolutionary Algorithm-Part II: Application example. *IEEE Transactions on Systems, Man, and Cybernetics. Part A: Systems and Humans*, vol. 28, nº 1, págs. 38-47, enero 1998.
- [Forrest93] Forrest, S. ed. Proceedings of the Fifth International Conference on Genetic Algorithms. Morgan Kaufmann, 1993.
- [Fossen94] Fossen, T. I. Guidance and Control of Ocean Vehicles. J.Wiley and Sons, New York, 1994.
- [Fourman85] Fourman, M.P. Compaction of symbolic layout using genetic algorithms, en J.J. Grefenstette (Ed.). Proceedings of an International Conference on Genetic Algorithms and Their Applications, Pittsburgh, PA, págs 141-153, sponsored by Texas Instrument and U.S. Navy Centre for Applied Research in Artificial Intelligence. (NCARAI), 1985.
- [Fraser57] Fraser, A.S. Simulation of Genetic Systems by Automatic Digital Computers. I. Introduction, *Australian Journal of Biological Sciences*, vol. 10, págs. 484-491, 1957.



- [Friedman56] Friedman, G.J. Selective Feedback Computers for Engineering Synthesis and Nervous System Analogy, Tesis doctoral, UCLA, 1956.
- [Froment61] Froment, G.F. y Bischoff, K.B. Kinetic data and product distributions from fixed bed catalytic reactors subject to catalytic fouling. Chemical Engineering Science, pág.16 189, 1961.
- [Fukuyama03] Fukuyama, Y. Fundamentals of Particle Swarm Techniques, en Modern Heuristics Optimization Techniques with applications to Power Systems. IEEE Tutorial, editado por K.Y. Lee y M.A. El Sharkawi, 2003.
- [García92] García Ruiz, J. L. 1992: "Patrón Oro, banca y crisis (1875-1936)", Cuadernos de Estudios Empresariales, No. 2, Editorial Complutense, Madrid.
- [Gately96] Gately E. Neural Networks for Financial Forecasting. Jon Wiley & Sons. 1996.
- [Gibson89] Gibson, George (1889), The Stock Exchanges of London Paris and New York, G. P. Putnman & Sons, New York.
- [Glover89] Glover, F. Tabu Search-Part I. ORSA Journal on Computing, 1(3), pág. 190-206, 1989.
- [Glover90] Glover, F. Tabu Search-Part II. ORSA Journal on Computing, 2(1), pag. 4-32, 1990.
- [Glover93] Glover, F., Taillard, E. y Werra, D. de. A user's guide to tabu search. Annals of Operations Research, vol. 41, pág. 3-28, 1993.
- [Glover97] Glover, F. y Laguna M. Tabu Search. Kluwer Academic Publishers, Boston, 1997.
- [Glover00] Glover, F. y Laguna M. Tabu Search. Handbook of Applied Optimization, en P.M. Pardalos y M.G.C. Resende eds. Oxford Academic Press, 2000.
- [Goldberg87] Goldberg, D.E. y Richardson, J.J. Genetic Algorithms with sharing for multimodal function optimization, en Genetic Algorithms and their Applications: Proceeding of the second ICGA, Hillsdale, Lawrence Erlbaum Associates, 1987.
- [Goldberg89] Goldberg, D.E. Genetic Algorithms in Search, Optimization, and Machine Learning. Addison-Wesley, 1989.
- [Goldberg90] Goldberg, D. E. Real-coded genetic algorithms, virtual alphabets, and blocking. Complex Systems, 5:139–167, 1990.
- [Goldberg91] Goldberg D. E., Deb K., Korb B. Don't worry, be messy. In R. Belew y L. Booker, editors, Proc. of the 4th International Conference on Genetic Algorithms, pages 24–30. Morgan Kaufmann, 1991.

- [Goldberg91a] Goldberg D. E., Deb K. A comparative analysis of selection schemes used in genetic algorithms. In *Foundations of Genetic Algorithms*, pages 69–93. Morgan Kaufmann, 1991.
- [Goldberg92] Goldberg, D.E., Deb, K. y Horn, J. Massive Multimodality, Deception, and Genetic Algorithms, en R. Männer and B. Manderick, editors, *Parallel Problem solving from Nature*, pág. 37-46. Amsterdam, Elsevier, 1992.
- [Goldberg99] Goldberg, D. Using Time Efficiently: Genetic-Evolutionary Algorithms and the Continuation Problem. *Proceedings of GECCO'99*, Vol.I, pp.212-219, julio 1999.
- [Gong02] Gong, W. y Shi, L. Modelling, Control and Optimization of Complex Systems: In Honour of Professor Yu-Chi Ho, *Kluwer International Series on Discrete Event Dynamic Systems*, nº 14, 2002.
- [González03] González M. C. “Nuevas perspectivas del Análisis Técnico de los mercados bursátiles mediante el aprendizaje automático. Aplicaciones al Índice General de la Bolsa de Madrid”. Universidad de Las Palmas de Gran Canaria. 2003.
- [Graham69] Graham. R.L. Bounds on multiprocessor timing anomalies. *SIAM Journal of Applied Mathematics*, 17: 416-429, 1969.
- [Grefenstette85] Grefenstette, J.J., ed. *Proceedings of the First International Conference on Genetic Algorithms*. Lawrence Erlbaum Associates, 1985.
- [Grefenstette86] Greffenstette, J. J. Optimization of control parameters for genetic algorithms. *Systems, Man and Cybernetics*, IEEE Transactions on, 16(1):122–128, jan. 1986. ISSN 0018-9472. doi:10.1109/TSMC.1986.289288.
- [Grefenstette89] Greffenstette J. J., Baker J. E. How genetic algorithms work: A critical look at implicit parallelism. In *Proceedings of the 3rd International Conference on Genetic Algorithms* , pages 20–27, San Francisco, CA, USA, 1989. Morgan Kaufmann Publishers Inc. ISBN 1-55860-066-3.
- [Gregory08] Gregory-Allen, Russell B., Shawky, Hany A. and Stangl, Jeffrey, “Quantitative vs. Fundamental Analysis in Institutional Money Management: Where's the Beef?”. 2008. Available at <http://ssrn.com/abstract=1269715>.
- [Greider89] Greider W. *Secrets of the Temple: How the Federal Reserve Runs the Country*. Touchstone Pr; Edición: Touchstone.(1989). ISBN-10: 0671675567.
- [Grossman80] Grossman, S., Stiglitz J. On the Impossibility of Informationally Efficient Markets. *American Economic Review*, 70, 393-408, 1980.
- [Gupta95] Gupta, Y. P. Semiexhaustive search for solving nonlinear optimal control problems. *Ind. Eng. Chem. Res.*, vol.34, pág. 3878-3884, 1995.

- [Hajela92] Hajela, P. y Lin, C.Y. Genetic search strategies in multicriterion optimal design. *Structural Optimization* vol.4, pág.99-107, 1992.
- [Harik99] Harik, G. Cantú-Paz, E., Goldberg, D.E. y Miller, B. The gambler's ruin problem, genetic algorithms, and the sizing of populations. *Evolutionary Computation* vol. 7, nº 3, 1999.
- [Hart 91] Hart W. E. , Belew R. K.. Optimizing an arbitrary function is hard for the genetic algorithm. In *Proceedings of the Fourth International Conference on Genetic Algorithms* , pages 190–195. Morgan Kaufmann, 1991.
- [Herrera96] Herrera F., Lozano M., Verdegay J. Dynamic and heuristic fuzzy connectives-based crossover operators for controlling the diversity and convergence of real-coded genetic algorithms. *International Journal of Intelligent Systems*, 11(12):1013–1040, 1996. ISSN 08848173
- [Herrera00] Herrera, F. y Lozano, M. 2-loop real-coded genetic algorithms with adaptive-control of mutation step sizes. *Applied Intelligence*, vol. 13, nº 3, pág. 187-204, 2000.
- [Herreros00] Herreros López, Alberto. Diseño de controladores robustos multiobjetivo por medio de algoritmos genéticos. Tesis doctoral. Departamento de ingeniería de sistemas y automática, Escuela Técnica Superior de Ingenieros Industriales, Valladolid, 2000.
- [Hesser91] Hesser J. y Männer R.. Towards an optimal mutation probability for genetic algorithms. In *Proceedings of the 1st Workshop on Parallel Problem Solving from Nature* , PPSN I, pages 23–32, London, UK, 1991. Springer-Verlag. ISBN 3-540-54148-9.
- [Hassan05] Hassan R., Nath B. Stock Market Forecasting Using Hidden Markov Model: A New Approach. *Proceedings of the 2005 5th International Conference on Intelligent Systems Design and Applications (ISDA'05)*. 2005.
- [Hidalgo99] Hidalgo, J.I., Prieto, M. Andrés, B. y Esteban, S. A method for model parameter Identification Using Parallel Genetic Algorithms. *Proceedings of Recent Advances in Parallel Virtual Machine and Message Passing Interface*, 6th European PVM/MPI, User's Group Meeting, pág. 291-298 Barcelona, sept, 1999.
- [Hidalgo01] Hidalgo Pérez J.I. "Técnicas de Partición y Ubicación para Sistemas Multi-FPGA basadas en Algoritmos Genéticos". Tesis doctoral. Universidad Complutense de Madrid. Facultad de Ciencias Físicas, Departamento de Arquitectura de Computadores y Automática. 2001.
- [Hillier80] Hillier, F.S. y Lieberman, G.J. *Introduction to Operations Research*. 3<sup>rd</sup> edition, Holden Day, Inc., Oakland, CA, 1980.
- [Himmelblau92] Himmelblau, D. *Applied Nonlinear Programming*. Mc Graw-Hill, N.Y. 1992.

- [Ho94] Ho, Y.C. Heuristics, Rules of Thumb and the 80/20 Proposition. IEEE Transactions on Automatic Control, vol.39, nº 5, pág.1025-1027, mayo 1994.
- [Ho97] Ho, Y.C. On the Numerical solution of Stochastic Optimization Problems. IEEE Transactions on Automatic Control, vol.42, nº5, pág.727-729, 1997.
- [Holland68] Holland J. H. Hierarchical descriptions, universal spaces and adaptive systems. Defense Technical Information Center, Ft. Belvoir, 1968.
- [Holland92] Holland, J.H. Adaptation in Natural and Artificial Systems. University of Michigan Press, Ann Arbor, Michigan, 2nd edition, MIT Press, 1992.
- [Homaifar94] Homaifar A., Qi C., Lai S.. Constrained optimization via genetic algorithms. Simulation, 62(4):242, 1994. doi: 10.1177/003754979406200405.
- [Horn93] Horn, J. Nafpliotis, N. Multiobjective Optimization using the Niche Pareto Genetic Algorithm. Technical Report 93005, Illinois Genetic Algorithms Laboratory, 1993.
- [Horn94] Horn, J., Nafpliotis, N. y Goldberg, D.E. A Niche Pareto Genetic Algorithm for Multiobjective Optimization, en Proceedings de First IEEE Conference on Evolutionary Computation, IEEE, World Congress on Computation, Volume I, Piscataway, NJ, pág. 82-87. 1994.
- [Horn97] Horn, J. Multicriteria decision making, en T. Bäck, D.B.Fogel y Z. Michalewicz (Eds), Handbook of Evolutionary Computation. Bristol (UK), Institute of Physics Publishing, 1997.
- [Horst95] Horst, R. y Pardalos, P.M. Handbook of Global Optimization. Kluwer, Dordrecht. 1995.
- [Hüe97] Hüe, X. Genetic Algorithms for Optimisation Background and Applications. Edinburgh Parallel Computing Centre, Version 1.0 February 1997. Available from: <http://www.epcc.ed.ac.uk/epcc-tec/documents/>.
- [Hui03] Hui A., Using Genetic Programming to Perform Time-Series Forecasting of Stock Prices. Genetic Algorithms and Genetic Programming at Stanford. Stanford, California. 2003.
- [Hwang79] Hwang, C.L. Masud, A.S.M. Multiple Objectives decision Making Methods and Applications, Berlin, Springer, 1979.
- [Iba93] Iba H., Kurita T., De Garis H. and Sato T. System Identification using Structured Genetic Algorithms. Proceedings of the Fifth International Conference on Genetic Algorithms. San Mateo, CA: Morgan Kaufmann. Pags: 279-286. 1993.

- [Im08] Im S., Lee J. Adaptive crossover, mutation and selection using fuzzy system for genetic algorithms. *Artificial Life and Robotics*, 13(1):129–133, 2008. ISSN 14335298. doi: 10.1007/s10015-008-0545-1
- [Ingber89] Ingber, L. Very fast simulated annealing. *Journal of Mathematical Computer Modelling*, vol.12, nº8, págs.967-973, 1989.
- [Ingber93] Ingber, L. Simulated annealing: Practice versus theory. *Journal of Mathematical Computer Modelling*, vol.18, nº11, págs.29-57, 1993.
- [Ishibuchi96] Ishibuchi, H. y Murata, T. Multiobjective genetic local search algorithm, en *Proceedings of 1996 IEEE International Conference on Evolutionary Computation (ICEC'96)*, Piscataway, NJ, págs 119-124, 1996.
- [Ishibuchi03] Ishibuchi, H.; Yoshida, T.; Murata, T. 2003. Balance Between Genetic Search and Local Search in Memetic Algorithms for Multiobjective Permutation Flowshop Scheduling. *IEEE Transactions on Evolutionary Computation* 7(2):204-223.
- [Ivakhenko71] Ivakhenko A. G., *Polynomial Theory of Complex Systems*. *IEEE Transactions on Systems, Man and Cybernetics*. 1 (4). pp. 364-378. 1971. [Janikow91] Janikow, C. Z., Michalewicz, Z.. An experimental comparison of binary and floating point representations in genetic algorithms. In R. K. Belew y L. B. Booker, editors, *Proc. of the 4th International Conference on Genetic Algorithms*, pages 151–157. Morgan Kaufmann, 1991
- [Jaszkiewicz04] Jaszkiewicz, A. 2004. A Comparative Study of Multiple-Objective Metaheuristics on the Bi-Objective Set Covering Problem and the Pareto Memetic Algorithm. *Annals of Operations Research* 131, (1-4): 135-158.
- [Jeong96] Jeong, I.K. y Lee, J.J. Adaptive Simulated Annealing Genetic Algorithms for Control Applications. *International Journal of Systems Science*, vol.27, nº2, págs.241-253, 1996.
- [Jensen78] Jensen, M. Some anomalous evidence regarding market efficiency. *Journal of Financial Economics*. 12:33–56, 1978.
- [Joines94] Joines J., Houck C. On the use of non-stationary penalty functions to solve nonlinear constrained optimization problems with ga's. In *Evolutionary Computation, 1994. IEEE World Congress on Computational Intelligence., Proceedings of the First IEEE Conference on*, pages 579 –584 vol.2, jun 1994. doi: 10.1109/ICEC.1994.349995.
- [Kaboudan02] Kaboudan M. GP Forecasts of Stock Prices for Profitable Trading. *Evolutionary Computation in Economics and Finance*. Vol 2. Physica-Verlag, Heidelberg, pp. 359-382. 2002.

- [Karp77] Karp, R.M. Probabilistic analysis of partitioning algorithms for the traveling salesman problem in the plane. *Mathematics of Operations Research*, 2:209-224, 1977.
- [Keber02] Keber C. Evolutionary Computation in Option Pricing: Determining Implied Volatilities Based on American Put Options. *Evolutionary Computation in Economics and Finance*. Physica-Verlag, Heidelberg, pp. 399-415. 2002.
- [Kendall53] Kendall, M. G. The Analysis of Economic Time-Series—Part I: Prices. *Journal of the Royal Statistical Society. Series A (General)*, 116(1), 11–25, 1953.
- [Kennedy01] Kennedy, J., Eberhart, R.C: y Shi, Y. *Swarm Intelligence*. Morgan Kaufmann Publishers, San Francisco, 2001.
- [Keynes31] Keynes, John Maynard.. *Essays in Persuasion*. New York: Norton. 1931
- [Kiem02] Kiem, H. y Thai, L.H. The Association of Evolutionary Algorithms and Fuzzy Logic. *The 6th World Multiconference on Systemics, Cybernetics and Informatics*, Orlando (Florida), julio de 2002.
- [Kirkpatrick83] Kirkpatrick, S., Gelatt, C.D. y Vecchi, M.P. Optimization by Simulated Annealing. *Science*, nº220, pág.671-680, 1983.
- [Knowles99] Knowles, J.D., Corne, D.W. (1999) The Pareto Archived Evolution Strategy : A New Baseline Algorithm for Pareto Multiobjective Optimisation. In *Proceedings of the 1999 Congress on Evolutionary Computation (CEC'99)*, pages 98-105. [cec99.ps.gz](http://cec99.ps.gz)
- [Knowles00] Knowles, J.D., Corne, D.W. (2000) Approximating the nondominated front using the Pareto Archived Evolution Strategy. *Evolutionary Computation*, 8(2), pp. 149-172. Draft version. Final version obtainable from MIT press.
- [Knowles02] Knowles, Joshua D. *Local-Search and Hybrid Evolutionary Algorithms for Pareto Optimization*. Tesis doctoral, Universidad de Reading, 2002.
- [Kocis97] Kocis, L. y Whiten, W.J. Computational investigations of low discrepancy sequences. *ACM Transactions on Mathematical Software*, vol.23, nº2, pág.266-294.
- [Koopmans71] Koopmans, T.C. Analysis and Production as an Efficient Combination of Activities, en *Activity Analysis of Product and Allocation*, editado por T.C. Koopmans, Yale University Press, New Haven London, pp.33-97, 1971 (originalmente publicado en 1951).
- [Korvin57] Korvin-Kroukoski, B.V. y Jacobs, W.R. Pitching and Heaving Motions of a Ship in Regular Waves. *SNAME T.*, nº65, pág. 590-632, 1957.
- [Koski84] Koski, J. Multicriterion optimization in structural design, en E. Atrek, R.H. Gallagher, K.M. Ragsdell y O.C. Zienkiewicz (Eds.), *New Directions in Optimum Structural Design*, pág.483-503, Wiley, 1984.

- [Kothari05] Kothari, S.P. y J. B. Warner. Econometrics of event studies, en el capítulo 1 de B. Espen Eckbo (ed.), *Handbook of Corporate Finance: Empirical Corporate Finance* (Handbooks in Finance Series, Elsevier/North-Holland). 2005.
- [Koza89] Koza, J.R. Hierarchical Genetic Algorithms Operating on Populations of Computer Programs, en *Proceedings of the 11<sup>th</sup> Conference on Artificial Intelligence*, vol. 1, Morgan Kaufmann, pág. 768-774, 1989.
- [Koza92] Koza, J.R. *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. MIT Press, 1992.
- [Koza94] Koza, J.R. Genetic programming as a means for programming computers by natural selection. *Statistics and Computing*, 4(2):87–112, 1994. ISSN 09603174. doi: 10.1007/BF00175355.
- [Kristinsson92] Kristinsson, K. y Dumont, G.A. System Identification and Control Using Genetic Algorithms. *IEEE T. Sys. Man & Cyb*, vol 22, nº5, pág. 1033-1046, 1992.
- [Kursawe91] Kursawe, F. A variant of evolution strategies for vector optimization, en H.P. Schwefel y R. Manner (Eds.), *Parallel Problem Solving from Nature*, Proc. 1<sup>st</sup> Workshop PPSN, Berlín, pág.193-197, Springer, 1991.
- [Kutsurelis98] Kutsurelis J. E. "Forecasting Financial Markets using Neural Networks: An analysis of method and accuracy". Master Thesis Naval Postgraduate school. Monterey, California. September 1998.
- [Kwong95] Kwong, S. y Man, K.F. Improving Local Search in Genetic Algorithms for Numerical Global Optimization Using Modified GRID-point Search Technique, en *Genetic Algorithms in Engineering Systems: Innovations and Applications*, IEEE, septiembre 1995.
- [Laarhoven87] Laarhoven, P.J.M.van y Aarts, E.H.L. *Simulated Annealing: Theory and Applications*. D. Reidel, Dordrecht, Holland, first edition, 1987.
- [Laarhoven88] Laarhoven, P.J.M.van. *Theoretical and Computational Aspects of Simulated Annealing*. Tesis doctoral, Universidad de Róterdam, 1988.
- [Lanchares95] Lanchares Dávila, Juan. *Desarrollo de metodologías para síntesis y optimización de circuitos lógicos multinivel*. Tesis doctoral, Universidad Complutense de Madrid, 1995.
- [Lane93a] Lane, D. Artificial Worlds and Economics. *Journal of Evolutionary Economics*, 3: 89-107. 1993.
- [Lane93b] Lane, D. Artificial Worlds and Economics. *Journal of Evolutionary Economics*, 3: 177-197. 1993.

- [Laumanns98] Laumanns, M., Rudolph, G. y Schwefel, H.P. A spatial predator-prey approach to multiobjective optimization: A preliminary study, en A.E. Eiben, T. Bäck, M. Schoenauer y H.P. Schwefel (Eds.), *Fifth International Conference on Parallel Problem Solving from Nature (PPSN-V)*, Berlín, Alemania, págs.241-249. Springer, 1998.
- [Laumanns00] Laumanns, M., Zitzler, E. y Thiele, L. A Unified Model for Multi-Objective Evolutionary Algorithms with Elitism. *Proceedings of the 2000 Congress on Evolutionary Computation*, págs. 46-53, IEEE, 2000.
- [LeRiche95] Le Riche R. G., Knopf-Lenoir C., Haftka R. T. T.. A Segregated Genetic Algorithm for Constrained Structural Optimization, pages 558–565. Morgan Kaufmann, 1995.
- [Lewis89] Lewis, E.V. *Principles of Naval Architecture*. The Society of Naval Architects and Marine Engineers, New Jersey, 1989.
- [Lee95] Lee M. A., Takagi H. A Framework for Studying the Effects of Dynamic Crossover, Mutation, and Population Sizing in Genetic Algorithms, volume 1011, pages 111–126. Springer Verlag, 1995.
- [Lemonge04] Lemonge A., Barbosa H. An adaptive penalty scheme for genetic algorithms in structural optimization. *International Journal for Numerical Methods in Engineering*, 59(5):703–736, 2004. ISSN 00295981. doi:10.1002/nme.899.
- [Leroy73] Leroy, S. Risk Aversion and the Martingale Property of Stock Returns. *International Economic Review*. 14, 436-446, 1973.
- [Leyva13] I. Leyva, A. Navas, I. Sendiña-Nadal, J. Almendral, M. Zanin, D. Papo, and B. S., “Explosive transitions to synchrony in networks of phase oscillators,” *Scientific Reports*, accepted for publication, 2013.
- [Li05] Li Rong-Jun, Xiong Zhi-Bin. Forecasting Stock Market with fuzzy neural networks. *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics*. 6. pp. 3475 – 3479. Guangzhou. 6. Pp August 2005.
- [Liepins90] Liepins G. E., Vose M. D. Representational issues in genetic optimization. *Journal of Experimental & Theoretical Artificial Intelligence*, 2(2):101–115, 1990. doi: 10.1080/09528139008953717.
- [Lin98] Lin, J y Hwang C. Enhancement of the global Convergence of Using Iterative Dynamic Programming to Solve Optimal Control Problems. *Ind. Eng. Chem. Res.*, nº37, págs.2469-2478, 1998.
- [Lis97] Lis, J. y Eiben, A.E. A multisexual genetic algorithm for multiobjective optimization, en *Proceedings of 1997 IEEE International Conference on Evolutionary Computation (ICEC'97)*, Piscataway, NJ., págs.59-64, IEEE, 1997.



- [Lloyd88] Lloyd, A.R.J.M. Seakeeping: Ship Behaviour in Rough Weather. Ellis Horwood (John Wiley and Sons), New York, 1988.
- [Lo88] Lo, A. W. y C. MacKinley, (1988) "*Stock Market Prices Do Not Follow Random Walks: Evidence from a Simple Specification Test*". Review of Financial Studie, 1, 41-66.
- [Lo90] Lo, A. y MacKinley C.A. Data snooping biases in test of financial asset pricing models, The Review of Financial Studies, 3, pp. 431–467. 1990.
- [Lo00] Lo A.W, Mamayssky J, Wang, J. "*Foundations of technical analysis: computational algorithms, statistical inference and empirical implementation*". The Journal of Finance. LV, 4, 1705-1765, 2000.
- [Lohpetch09] Lohpetch D., Corne D. Discovering Effective Technical Trading Rules with Genetic Programming: Towards Robustly Outperforming Buy-and-Hold. In World Congress on Nature and Biologically Inspired Computing (NABIC) 2009, IEEE Press. pp. 431—437, 2009.
- [Lohpetch10] Lohpetch D., Corne D. Outperforming Buy-and-Hold with Evolved Technical Trading Rules: Daily, Weekly and Monthly Trading. EvoApplications 2010, (6025) pp. 161 - 171, Springer LNCS. 2010.
- [Lohpetch11] Lohpetch D. and Corne D. Multi-objective algorithms for financial trading: Multi-objective out-trades single-objective. IEEE Congress on Evolutionary Computation 2011, 192-199. 2011.
- [Loughlin97] Loughlin, D.H. y Ranjithan, S. The neighbourhood constraint-method: A genetic algorithm-based multiobjective optimization technique, en T. Bäck (Ed.), Proceedings of the Seventh International Conference on Genetic Algorithms, San Francisco, California, pág.666-673, Morgan Kaufmann, 1997.
- [Lucas78] Lucas, R. Asset Prices in an Exchange Economy. Econometrica, 46, 1429-1446, 1978.
- [Lucas80] Lucas, Robert E., Jr. The Death of Keynesian Economics. Issues and Ideas (Uni-versity of Chicago, Chicago, IL). Winter, pp. 18-19, 1980.
- [Luke01] Luke, S. When short runs beat long runs. Proceedings of Genetic and Evolutinary Computation Conference, pág.74-80, 2001.
- [Luke09] Luke, S. Essentials of metaheuristics : a set of undergraduate lecture notes. Lulu, [S.l.], 2009
- [Luus90] Luus, R. Optimal control by dynamic programming using systematic reduction in grid size. Int. J. Control, nº51, pág.995-1013, 1990.
- [Luus91a] Luus, R Effect of the choice of final time in optimal control of non linear systems. Can. J. Chem. Eng., nº69, pág.144-151, 1991.

- [Luus91b] Luus, R. Application of iterative dynamic programming to state constrained optimal control problems. *Hung. J. Ind. Chem.*, nº19, pág.245-254, 1991.
- [Luus91c] Luus, R. y Rosen, O. Application of dynamic programming to final state constrained optimal control. *Ind. Eng. Chem. Res.*, nº30, pág.1525-1530, 1991.
- [Luus93] Luus, R. Piecewise linear continuous optimal control by iterative dynamic programming. *Ind. Eng. Chem. Res.*, nº32, pág.859-865, 1993.
- [Madsen98] Madsen, K. y Zertchaninov, S. A New Branch and Bound Method for Global Optimization. Technical Report IMM-REP-1998-05, Departamento de Modelado Matemático, Universidad Técnica de Dinamarca, 1998.
- [Magdon00] Magdon-Ismail, A. The early restart algorithm. *Neural Computation*, nº12, pág.1303-1312, 2000.
- [Mago09] Mago P. y Chamra L., "Analysis and optimization of CCHP systems based on energy, economical, and environmental considerations", *Energy and Buildings* (2009).
- [Mahfoud93] Mahfoud, S.W. An Analysis of Boltzmann Tournament Selection. *Complex Systems*, vol.7, nº2, pág.155-170, 1993.
- [Mahfoud94] Mahfoud, S.W. Crossover Interactions among Niches, en *Proceedings of the First IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence*, pág. 188-193, 1994.
- [Malkiel73] Malkiel, B. G. The Efficient Market Hypothesis and its Critics. *Journal of Economic Perspectives*, vol 17, no. 1, 59-82, 2003.
- [Malkiel92] Malkiel, B. Efficient Market Hypothesis. in Newman, P., Milgate, M., and Eatwell, J. (eds.), *New Palgrave Dictionary of Moneyand Finance*, Macmillan, London, 1992.
- [Mankiw85] Mankiw, N. Gregory. Small Menu Costs and Large Business Cycles: A Macroecono-mic Model of Monopoly. *Quarterly Journal of Economics*. May, 100:2, pp. 529-537, 1985.
- [Masaharu03] Masaharu Munetomo, Naoya Murao, and Kiyoshi Akama. 2003. A parallel genetic algorithm based on linkage identification. In *Proceedings of the 2003 international conference on Genetic and evolutionary computation: PartI (GECCO'03)*, Erick Cantú-Paz (Ed.). Springer-Verlag, Berlin, Heidelberg, 1222-1233
- [Mercer78] Mercer R., Sampson J. Adaptive search using a reproductive metaplan. *Kybernetes*, 7:215–228, 1978. doi: 10.1108/eb005486.

- [Marchiorri99] Marchiorri, E. y Rossi, C. A flipping Genetic Algorithm for Hard SAT Problems. Proceedings of the Genetic and Evolutionary Computation Conference, GECCO99, 13-17 jul 99, vol 1, pág. 393-400.
- [Menger71] Menger, C (1997). Principios de Economía Política (2a edición). Madrid: Unión Editorial. ISBN 978-84-7209-316-4.
- [Michalewicz96] Michalewicz, Z. Genetic Algorithms + Data Structures = Evolution Programs. 3<sup>rd</sup> ed., Springer-Verlag, Berlin Heidelberg New York, 1996.
- [Michalewicz96a] Michalewicz Z., Nazhiyath G., Michalewicz M.. A note on usefulness of geometrical crossover for numerical optimization problems. In Evolutionary Programming'96, pages 305–312, 1996
- [Michalewicz00] Michalewicz, Z. y Fogel, D.B. How to Solve It: Modern Heuristics. Springer-Verlag, Berlín, 2000.
- [Miettinen99] Miettinen, K. M. Nonlinear Multiobjective Optimization. Kluwer Academic Publishers, 1999.
- [Mills96] Mills, T. "Technical analysis and the London stock exchange: Testing trading rules using the FT30". Economic Research Paper 96/1, Department of Economics, Loughborough of Technology. 1996.
- [Mitchell99] Mitchell, M. An Introduction to Genetic Algorithms. MIT press, fifth edition, 1999.
- [Morari01] Morari, M., Gentilini, A. Challenges and Opportunities in Process Control: Biomedical Processes. AIChE Journal, vol. 47, nº10, octubre 2001.
- [Morató99] Morató Izquierdo, M.C., Algoritmos genéticos: Aplicación al análisis de secuencias en biología molecular. Tesis doctoral, U.P.M., Escuela Técnica Superior de Ingenieros Agrónomos, Madrid, 1999.
- [Moros96] Moros, R., Kalies, H., Rex, H.G. y Schaffarczyk, St. A Genetic Algorithm for Generating Initial Parameter Estimations for Kinetic Models of Catalytic Processes. Computers Chem. Eng., vol. 20, nº10, pág. 1257-1270, 1996.
- [Moscato89] Moscato, y Norman, G. On Evolution, Search, Optimization, Genetic Algorithms and Martial Arts: Towards Memetic Algorithms
- [Moscato01] Moscato, N. NP Optimization Problems, Aproximability and Evolutionary Computation: From Practice to Theory. Tesis doctoral, Universidad de Campinas, Brasil, 2001.
- [Moggridge72] Moggridge, D. E. British Monetary Policy, 1924-1931, The Norman Conquest of \$ 4,86, Cambridge, 1972.
- [Mühlenbein92] Mühlenbein H. Parallel genetic algorithm in combinatorial optimization, 1992.

- [Mühlenbein93] Mühlenbein, H., y Schlierkamp-Voosen, D. Predictive models for the breeder genetic algorithm I: Continuous parameter optimization. *Evolutionary Computations*, vol.1, nº1, pág. 25-49, 1993.
- [Murata96] Murata, T., Ishibuchi, H. y Tanaka, H. Multi-objective genetic algorithm and its application to flowshop scheduling. *Computers&Industrial Engineering*, vol.30, nº4, pág.957-968, 1996.
- [Murata97] Murata, T. Genetic Algorithms for Multi-Objective Optimization. Tesis doctoral, Universidad de Osaka, febrero 1997.
- [Nebro09] Nebro A. J., Durillo J. J., Luna F., Dorronsoro B., and Alba., E. 2009. MOCeII: A cellular genetic algorithm for multiobjective optimization. *Int. J. Intell. Syst.* 24, 7 (July 2009), 726-746. DOI=10.1002/int.v24:7 <http://dx.doi.org/10.1002/int.v24:7>
- [Neely97] Neely, C., Weler, P. y Dittmar, R., Is technical analysis in the foreign exchange market profitable? a genetic programming approach, *Journal of Financial Quantitative Analysis*, 32 (4), pp. 405–426. 1997.
- [Nelson82] Nelson, R.R., Winter S.G. An Evolutionary Theory of Economic Theory of Economic Change. Harvard University Press. Massachusetts. Cambridge. 1982.
- [Oates99] Oates, M., Corne, D. y Turton, B.C.H. The effects of selection Pressure on Parameter Choice in Evolutionary Search. Late Breaking Papers of the Genetic and Evolutionary Computation Conference, GECCO99, 13-17 julio 1999, vol.1, pág.198-203.
- [Obayashi98] Obayashi, S., Takahashi, S., y Takeguchi, Y. Niching and elitist models for mogas, en A.E. Eiben, T. Bäck, M. Schoenauer y H.P. Schwefel (Eds.), Fifth International Conference on Parallel Problem Solving from Nature (PPSN-V), Berlín, Alemania. pág.260-269, Springer, 1998.
- [Odusanya02] Odusanya, A.A., Odetayo, M.O., Petrovic, D. y Naguib, R.N.G. A Genetic Algorithm Based Model for Breast Cancer Prognosis. The 6th World Multiconference on Systemics, Cybernetics and Informatics, Orlando (Florida), julio 2002.
- [Ono97] Ono, I. y Kobayashi, S.. A Real Coded Genetic Algorithm for Function Optimization Using Unimodal Normal Distributed Crossover, volume 14, page 1146–1155. Morgan Kaufmann, 1997.
- [Ono03] Ono, I. Kita, H. y Kobayashi, S. A real-coded genetic algorithm using the unimodal normal distribution crossover, pages 213–237. Springer-Verlag New York, Inc., New York, NY, USA, 2003. ISBN 3-540-43330-9.
- [Orvosh93] Orvosh D., Davis L. Shall we repair? genetic algorithmscombinatorial optimizationand feasibility constraints. In *Proceedings of the 5th*

- International Conference on Genetic Algorithms, pages 650–, San Francisco, CA, USA, 1993. Morgan Kaufmann Publishers Inc. ISBN 1-55860-299-2.
- [Orvosh94] Orvosh D., Davis L. Using a genetic algorithm to optimize problems with feasibility constraints. In *Evolutionary Computation, 1994. IEEE World Congress on Computational Intelligence., Proceedings of the First IEEE Conference on*, pages 548 –553 vol.2, jun 1994. doi: 10.1109/ICEC.1994.350001.
- [Osborne59] Osborne, M. Brownian Motion in the Stock Market, *Operations Research* 7, 145-173, 1959.
- [Oussaidène97] Oussaidène M., Chopard B., Pictet O. V., Tomassini M., *Parallel Genetic Programming and its application to trading model induction. Parallel Computing.* 23 (8). pp. 1183-1198. 1997.
- [Pacheco97] Pacheco, P.S. *Parallel programming with MPI.* Morgan Kaufman Publishers, 1997.
- [Papoulis91] Papoulis, A. *Probability, Random variables, and Stochastic Processes.* Mc Graw-Hill, Inc., third edition, 1991.
- [Pareto96] Pareto, V. *Cours D'Economie Politique, Volume I*, 1896. Lausanne: F.Rouge. (Existe una edición de Libraire Droz , Geneve, de 1964).
- [Parisi06] Parisi A., Parisi F., Díaz D. Modelos de Algoritmos Genéticos y Redes Neuronales en la Predicción de Índices Bursátiles Asiáticos. *Cuadernos de Economía.* Vol. 43. pags: 251-284. 2006.
- [Park88] Park, S., y Ramirez, W.F. Optimal production of secreted protein in fed-batch reactors. *AIChE J.*, vol.34, pág.1550-1558, 1988.
- [Parks98] Parks, G.T. y Miller, I. Selective breeding in a multiobjective genetic algorithm, en A. E. Eiben, T. Bäck, M. Schoenauer y H.P. Schwefel (Eds.), *Fifth International Conference on Parallel Problem Solving from Nature (PPSN-V)*, Berlín, Alemania, pág.250-259, Springer, 1998.
- [Peña05] Peña D. *Análisis de series temporales.* Alianza editorial, Madrid. 2005.
- [Pereira02] Pereira R. Forecasting Ability But No Profitability: An Empirical Evaluation of Genetic Algorithm-Optimised Technical Trading Rules. *Evolutionary Computation in Economics and Finance.* Physica-Verlag, Heidelberg, 2002. Págs. 273-286.
- [Pham00] Pham, D.T. y Karaboga, D. *Intelligent Optimisation Techniques*, Springer, 2000.
- [Plummer89] Plummer, T. *Forecasting Financial Markets: The Truth Behind Technical Analysis.* London: Kogan Page. 1989.

- [Poloni95] Poloni, C. Hybrid GA for multi-objective aerodynamic shape optimization. En G. Winter, J. Périaux, M. Galán y Cuesto, P. (Eds.). Genetic Algorithms in Engineering and Computer Science. New York, págs.397-415, Wiley, 1995.
- [Poon91] Poon, S.H, Taylor. Stock Returns and volatility: An empirical Analysis of the U.K. Stock Market, Journal of Banking and Finance. 1991.
- [Porter02] Porter, J. H. y Ramsey, K.W. Integrated Ecological Data: Tools and Techniques. The 6th World Multiconference on Systemics, Cybernetics and Informatics. Orlando (Florida), julio 2002.
- [Potter94] Potter, M. y De Jong, K.A. A Cooperative Coevolutionary Approach to Function Optimization, en Proceedings of the third Conference on Parallel Problem Solving from Nature. Lecture Notes in Computer Science, vol. 866, págs. 249-257, Springer, Berlin, 1994.
- [Pring91] Pring, M., Technical Analysis Explained: The Successful Investor's Guide to Spotting Investment Trends and Turning Points. New York: MacGraw-Hill. 1991.
- [Radcliffe91] Radcliffe, N. J.. Forma analysis and random respectful recombination. In ICGA'91, pages 222–229, 1991.
- [Rajan95] Rajan, S. D. Sizing, shape, and topology design optimization of trusses using genetic algorithm. Journal of Structural Engineering , 121(10):1480–1487–, 1995. doi: 10.1061/(ASCE)0733-9445(1995)121:10(1480).
- [Ramirez94] Ramirez, W. Fred. Process control and identification. Academic Press, Inc, 1994.
- [Rawlins91] Rawlins, G.J.E., editor. Foundations of Genetic Algorithms. Morgan Kaufmann, 1991.
- [Rechenberg70] Rechenberg I. Evolutionsstrategie Optimierung technischer Systeme nach Prinzipien der biologischen Evolution . PhD thesis, Frommann-Holzboog, Stuttgart-Bad Cannstatt, 1970.
- [Rechenberg73] Rechenberg, I. Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution. Fromman-Holzbog, Stuttgartr, 1973.
- [Rechenberg94] Rechenberg, I. Evolutionsstrategie'94. Fromman-Holzboog, Stuttgart, 1994.
- [Reeves93] Reeves, C. Modern Heuristic Techniques for Combinatorial Problems. Blackwell Scientific Publications, Oxford, 1993.
- [Rehnström00] Rehnström, A. Automatic Control of an Activates Sludge Process in a Wastewater Treatment Plant- a Benchmark Study. Tesis doctoral, Universidad de Uppsala (Suecia), 2000.

- [Reynozo11] Reynoso-Meza, G., Sanchis, J., Blasco, X., Martínez, M., April 2011d. An empirical study on parameter selection for multiobjective optimization algorithms using differential evolution. In: Proceedings of the 2011 IEEE Symposium on Differential Evolution (SDE2011).
- [Rodríguez99] Rodríguez V., K. Multiobjective Evolutionary Algorithms in Non-Linear System Identification. Tesis doctoral, Department of Automatic Control and Systems Engineering, Universidad de Sheffield, 1999.
- [Rojas02] Rojas, I., González, J., Pomares, H., Merelo, J.J., Castillo, P.A., y Romero, G. Statistical Analysis of the Main Parameters Involved in the Design of a Genetic Algorithm. IEEE Transactions on Systems, Man and Cybernetics, Part C: Applications and Reviews, vol.32, nº1, febrero 2002.
- [Rubinstein76] Rubinstein, M. The Valuation of Uncertain Income Streams and the Pricing of Options . Bell Journal of Economics 7, 407-425, 1976.
- [Rubinstein92] Rubinstein, R. Monte Carlo Optimization, Simulation and Sensitivity of Queuing Networks. Krieger, Malabar, Florida, 1992.
- [Rudolph98] Rudolph, G. On a multiobjective evolutionary algorithm and its convergence to the pareto set, en IEEE International Conference on Evolutionary Computation (ICEC'98), Piscataway, NJ., pág.511-516, IEEE, 1998.
- [Ryan95] Ryan, C. Niche and species formation in genetic algorithms, en L. Chambers (Ed.), Practical Handbook of Genetic Algorithms, Volume 1, Chapter 2, pág.57-74, Boca Raton, CRC Press, 1995.
- [Salvesen70] Salvesen, N., Tuck, E.O. y Faltinsen, O., Ship Motions and Sea Loads. SNAME T., nº78, pág.250-285, 1970.
- [Samuelson65] Samuelson, P. A. Proof that properly anticipated prices fluctuate randomly. Industrial Management Review. 6:41–50, 1965.
- [Sanada95] Sanada, K. & Kitikawa, A. Robust control of a closed-loop pressure control system considering pipeline dynamics. Trans. Of Japan Society of Mechanical Engineers, vol. 61, pág.3559-3566, 1995.
- [Sanchez12] Sanchez Caballero, S. Tesis Doctoral "Optimización estructural y topológica de estructuras morfológicamente no definidas mediante algoritmos genéticos".
- [Santini01] Santini M., Tettamanzi A., Genetic Programming for Financial Time Series Prediction. Genetic Programming, Proceedings of EuroGP'2001. Vol. 2038. Springer-Verlag. Pags. 361-370. Italy 2001.
- [Sargent75] Sargent, Thomas J. and Neil Wallace. 1975. "Rational Expectations, the Optimal Monetary Instrument, and the Optimal Money Supply Rule." Journal of Political Economy. April, 83:2, pp. 241-54

- [Sawaragi85] Sawaragi, Y., Nakayama, H. y Tanino, T. Theory of Multiobjective Optimization. Orlando, Florida, Academic Press, 1985.
- [Schaffer84] Schaffer, J.D. Multiple Objective Optimization with Vector Evaluated Genetic Algorithms. Tesis doctoral, Vandebrit University, 1984.
- [Schaffer85] Schaffer, J.D. Multiple Objective Optimization with Vector Evaluated Genetic Algorithms, en J.J. Grefenstette (Ed.), Proceedings of an International Conference on Genetic Algorithms and Their Applications. Pittsburgh, PA, págs.93-100, sponsored by Texas Instrument and U.S. Navy Centre for Applied Research in Artificial Inteligence. (NCARAI), 1985.
- [Schaffer89] Schaffer J. D. , Caruana R. A., Eshelman L. J., Das R. A study of control parameters affecting online performance of genetic algorithms for function optimization. In Proceedings of the third international conference on Genetic algorithms, pages 51–60, San Francisco, CA, USA, 1989. Morgan Kaufmann Publishers Inc. ISBN 1-55860-006-3
- [Schwefel77] Schwefel, H.P. Numerische Optimierung von Computer-Modelln mittels der Evolutionsstrategie. Birkhäuser, Verlag, Basel, 1977.
- [Schwefel81] Schwefel, H.P. Numerical Optimization of Computer Models. New York, John Wiley&Sons,1981.
- [Shahookar90] Shahookar K., Mazumder P.. A genetic approach to standard cell placement using meta-genetic parameter optimization. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 9(5):500–511, 1990. doi: 10.1109/43.55180.
- [Ship98] Silvia Ana: Results of First Year's Service. Ship&Boat Intl., págs.15-16, enero/febrero 1998.
- [Silva02] Silva, V.V.R y Fleming, P.J. Control Configuration Design Using Evolutionary Computing. 15<sup>th</sup> Triennial World Congress, Barcelona, 2002.
- [Sinha02] Sinha, A. Designing efficient genetic and evolutionary algorithm hybrids. Master's thesis, University of Illinois, Urbana Champaign, 2002.
- [Smith94] Smith, A. Imperfect competition and international trade. D.Greenaway y L.A. Winters (Eds.). Surveys in International Trade. Basil Blackwell.Oxford. 1994.
- [Smith98] Smith J., Vavak F. Replacement strategies in steady state genetic algorithms: Static environments. In FOGA'98, pages 219–234, 1998
- [Smith07] Smith J. On replacement strategies in steady state evolutionary algorithms. Evol. Comput., 15:29–59, March 2007. ISSN 1063-6560. doi: 10.1162/evco.2007.15.1.29.



- [Soltero12] Soltero, F. J., Bodas-Sagi, D. J., Fernández, P., Hidalgo, J. F. Fernández, Optimization of Technical Indicators in real time with Multiobjective Evolutionary Algorithms. In: *Proceedings of the 12th Annual Conference on Genetic and Evolutionary Computation. GECCO'12*. Philadelphia, USA. (Aceptado para su presentación como poster). 2012.
- [Song 96] Song Y., Wang G., Johns A., Wang P.. Improved genetic algorithms with fuzzy logic controlled crossover and mutation. Number 427 /1, pages 140–144, Exeter, UK, 1996. IEE, Stevenage, United Kingdom. Conference of Proceedings of the 1996 UKACC International Conference on Control. Part 1 (of 2); Conference Date: 2 September 1996 through 5 September 1996; Conference Code: 45597.
- [Spears94] Spears, W.M. Simple Subpopulation Schemes, en *Proceedings of the Fifth International Conference on Genetic Algorithms*, pág.296-307, 1994.
- [Spears98] Spears, W.M. The Role of Mutation and Recombination in Evolutionary Algorithms. Tesis doctoral, George Mason University, Fairfax, Virginia, 1998.
- [Srinivas94] Srinivas M., Patnaik L.. Adaptive probabilities of crossover and mutation in genetic algorithms. *IEEE Transactions on Systems, Man and Cybernetics*, 24(4):656–667, 1994. ISSN 00189472. doi: 10.1109/21.286385
- [Srinivas95] Srinivas, N. y Deb, K. Multiobjective optimization using nondominated sorting in genetic algorithms. *Evolutionary Computation*, vol.2, nº3, pág.221-248, 1995, URL [citeseer.nj.nec.com/srinivas94multiobjective.html](http://citeseer.nj.nec.com/srinivas94multiobjective.html)
- [Srivastava01] Srivastava, R.P. y Goldberg, D.E. Verification of the theory of genetic and evolutionary continuation. *Proceedings of the Genetic and Evolutionary Computation Conference 2001*, pág.623-630.
- [Srivastava02] Srivastava, R.P. Time Continuation in Genetic Algorithm. Thesis IlliGAL Report Nº 2001021, junio 2002.
- [Steuer86] Steuer, R.E. Multiple Criteria Optimization: Theory, Computation and Application. New York, Wiley, 1986.
- [Steven02] Steven, H.L., Paganini, F. y Doyle, C. Internet Congestion Control. *IEEE Control Systems Magazine*, Febrero 2002.
- [Syswerda89] Syswerda, G. Uniform crossover in genetic algorithms, en Schaffer 1989, pág.2-9, 1989.
- [Szepe68] Szepe, Stephen y Levenspiel, Octave. Optimal temperature policies for reactors subject to catalyst deactivation-I. Batch reactor. *Chemical Engineering Science*, vol.23, pág.881-894, Pergamon Press, 1968.

- [Szpiro02] Szpiro G. G. Tinkering with Genetic Algorithms: Forecasting and Data Mining in Finance and Economics. *Evolutionary Computation in Economics and Finance*. Physica-Verlag, Heidelberg, pp. 273-286. 2002.
- [Tamaki94] Tamaki, H., Mori, M., Araki, M., Mishima, Y. y Ogai, H. Multicriteria optimization by genetic algorithms: A case of scheduling in hot rolling process, en M. Fushimi and K. Tone (Eds.), *Proceedings of APORS'94*, Singapur, págs.374-381, World Scientific Publishing, 1994.
- [Tamaki96] Tamaki, H., Kita, H. y Kobayashi, S. Multiobjective optimization by genetic algorithms: A review, en *Proceedings of 1996 IEEE International Conference on Evolutionary Computation (ICEC'96)*, Piscataway, NJ., págs.517-522, IEEE, 1996.
- [Tate95] Tate D. M. Smith A. E. A genetic approach to the quadratic assignment problem, 1995.
- [Taylor78] Taylor, P.D., Jonker L.B. Evolutionary stable strategies and gamedynamics. *Mathematical Biosciences*, 40: 145-156, 1978.
- [Taylor92] Taylor, M. y Allen, H. The use of technical analysis in the foreign exchange market, *Journal of Money and Finance*, 11 (3), pp. 304–314. 1992.
- [Thierens94] D. y Goldberg D. E.. Convergence models of genetic algorithm selection schemes. In *Proceedings of the International Conference on Evolutionary Computation. The Third Conference on Parallel Problem Solving from Nature: Parallel Problem Solving from Nature , PPSN III*, pages 119–129, London, UK, 1994. Springer-Verlag. ISBN 3-540-58484-6.
- [Timmer84] Timmer, G.T. *Global Optimization: A Stochastic Approach*. Centrum Voor Wiskunde en Informatica, Amsterdam, first edition, 1984.
- [Todd97] Todd, D.S. y Sen, P. A multiple criteria genetic algorithm for containership loading, en T. Bäck. (Ed.), *Proceedings of the Seventh International Conference on Genetic Algorithms*, San Francisco, California, págs.674-681, Morgan Kaufmann, 1997.
- [Törn89] Törn, A. y Zilinskas, A. *Global Optimization*. Springer, Berlín, 1989.
- [Triefin64] Triefin,R. The evolution of the international monetary system: Historical reappraisal and future perspectives, New Haven.(1964).
- [Tsutsui02] Tsutsui, S. y Goldberg, D. E.. Simplex crossover and linkage identification: Single-stage evolution vs. multi-stage evolution. In *in: Proceedings IEEEInternational Conference on Evolutionary Computation*, 2002, pages 974–979, 2002.
- [Tuson96] Tuson A., Ross P. Co-evolution of operator settings in genetic algorithms. *Evolutionary computation*, 6:161–184, 1996.

- [Tunzelmann91] Tunzelmann, N. Malthus as an Evolutionary Economist. *Journal of Evolutionary Economics*, 1: 273-291, 1991.
- [Uraikul00] Uraikul, V., Chan, C.W. y Tontiwachwuthikul, P. Development of an expert system for optimizing natural gas pipeline operations. *Expert Systems with Applications*, vol. 18, pág. 271-282, 2000.
- [Uriel85] Uriel E. *Análisis de Series Temporales. Modelos ARIMA*. Paraninfo. Madrid. 1985.
- [Valenzuela97] Valenzuela-Rendón, M. y Uresti-Charre. A non-generational genetic algorithm for multiobjective optimization, en T. Bäck (Ed.), *Proceedings of the Seventh International Conference on Genetic Algorithms*, San Francisco, California, pág.658-665, Morgan Kaufmann, 1997.
- [Vanderpooten90] Vanderpooten, D. Multiobjective Programming: Basic Concepts and Approaches, *Stochastic versus Fuzzy Approaches to Multiobjective Mathematical Programming under Uncertainty*. Editado por R. Slowinski y J. Teghem, Kluwer Academic Publishers, pág.7-22, Dordrecht, 1990.
- [VanSluijs72] Van Sluijs y Gie, T.S., Behaviour and Performance of Compact Frigates in Head Seas. *Int. Shipbuilding Progress*, vol.19, nº210, pág.35-52, 1972.
- [Veldhuizen98a] Veldhuizen, D.A.V. y Lamont, G.B. Evolutionary computation and convergence to a pareto front, en J.R. Koza, W. Banzhaf, K. Chelapilla, K. Deb, M. Dorigo, D.B. Fogel, M.H. Garzon, D.E. Goldberg, H. Iba y R. Riolo (Eds.), *Genetic Programming, Proceedings of the Third Annual Conference*. San Francisco, California, pág 22-25, Morgan Kaufmann, 1998.
- [Veldhuizen98b] Veldhuizen, D.A.V. y Lamont, G.B. Multiobjective evolutionary algorithm research: A history and analysis. Technical Report TR-98-03, Department of Electrical and Computer Engineering, Graduate School of Engineering, Air Force Institute of Technology, Wright-Patterson AFB, Ohio, 1998.
- [Veldhuizen99] Veldhuizen, D.A.V. *Multiobjective Evolutionary Algorithms: Classification, Analyses, and New Innovations*. Tesis doctoral, Department of Electrical and Computer Engineering. Graduate School of Engineering. Air Force Institute of Technology, Wright-Patterson AFB, Ohio, 1999.
- [Voigt95] Voigt, H.M., Mühlenbein, H. y Cvetkovic, D. Fuzzy recombination for the breeder genetic algorithm, en Eshelman95, pág. 104-111, 1995.
- [Vose99] Vose, M.D. *The simple genetic algorithm*. MIT press, first edition, 1999.
- [Vrajitoru00] Vrajitoru, D. Soft computing in information retrieval. Techniques and applications (Chapter Large Population or Many Generations for Genetic Algorithms? Implications in Information Retrieval, pág.199-222), *Physica-Verlag*, Heidelberg, 2000.

- [Walters 95] Walters, G. A., Smith, D. K. Evolutionary design algorithm for optimal layout of tree networks. *Engineering Optimization*, 24(4):261–281, Aug.1995. ISSN 0305-215X. doi: 10.1080/03052159508941193.
- [Wermers07] Wermers, R. T. Yao, J Zhao. “The Investment Value of Mutual Fund Portfolio disclosure”. Working Paper, University of Maryland. 2007.
- [West88] West, K. D. Bubbles, fads and stock price volatility: A partial evaluation, *Journal of Finance*, 43, 639–660. 1988.
- [Wetzel83] Wetzel A. Evaluation of the Effectiveness of Genetic Algorithms in Combinatorial Optimization. PhD thesis, University of Pittsburgh, 1983.
- [Whitley89] Whitley D. The genitor algorithm and selection pressure: Why rank-based allocation of reproductive trials is best. In *Proceedings of the Third International Conference on Genetic Algorithms*, pages 116–121. Morgan Kaufmann, 1989.
- [Whitley95] Whitley, D. Mathias, K., Rana, S. y Dzubera, J. Building Better Test Functions. En *Proceedings of the Sixth International Conference on Genetic Algorithms*, Morgan Kaufmann, San Mateo, CA, 1995.
- [Whidborne96] Whidborne, J.F. y Gu, D.W. Simulates Annealing for Multiobjective Control System Design, en *UKACC International Conference on Control*, pág.376-381, Conference Publication nº427, IEEE, septiembre 1996.
- [Wolpert97] Wolpert, D.H. y Macready, W.G. No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, vol.1, nº1, pág.67-82, abril 1997.
- [Woon03] Woon S. , Querin O., y Steven, G. On improving the ga step-wise shape optimization method through the application of the fixed grid fea paradigm. *October* , 25(2003):270–278, 2003.
- [Working34] Working, Holbrook. A Random-Difference Series for Use in the Analysis of Time Series. *Journal of the American Statistical Association*, 29 (185), 11–24, 1934.
- [Wright91] Wright, A.H. Genetic Algorithms for Real Parameter Optimization, en [Rawlins91], pág.205-218, 1991.
- [Wu00] Wu, S., Ríos-Mercado, R.Z., Boyd, E.A. y Scott, L.R. Model Relaxations for the fuel cost minimization of steady-state gas pipelines networks. *Mathematical and Computer Modelling*, vol. 31, pág.197-220, 2000.
- [Wu03] Wu B., Yu X., Liu L.. Fuzzy penalty function approach for constrained function optimization with evolutionary algorithms. 2003.
- [www-BicMac] Indice BigMac. <http://www.economist.com/content/big-mac-index>

- [www-Coello] Coello Coello, C.A., Depto. de Ingeniería Eléctrica, Sección de Computación, Instituto Politécnico Nacional de México, <http://delta.cs.cinvestav.mx/~ccoello/EMOO/>.
- [www-dukascopy] Página sobre el mercado de divisas, <http://www.dukascopy.com/>
- [www-ISO-4217] Norma ISO-4217 [http://es.wikipedia.org/wiki/ISO\\_4217](http://es.wikipedia.org/wiki/ISO_4217)
- [www-Iridia] Página sobre la optimización por colonias de hormigas de Marco Dorigo .Universidad libre de Bruselas, <http://iridia.ulb.ac.be/~mdorigo/ACO/about.html>.
- [www-navy] Página sobre algoritmos genéticos de la marina de los Estados Unidos, <http://www.aic.nrl.navy.mil/galist/>
- [www-metatrader] Aplicación para la operativa en tiempo real de los mercados financieros, <http://www.metatrader4.com/es>
- [www-mql4] Lenguaje de programación para la plataforma metatrader 4.0, <http://www.mql4.com/>
- [www-Shandy] Página sobre la teoría de la paridad de los tipos de interés. [http://en.wikipedia.org/wiki/Interest\\_rate\\_parity](http://en.wikipedia.org/wiki/Interest_rate_parity)
- [www-Shi] Página sobre 'Swarm Particle' de Yuhui Shi. Escuela de Ingeniería y Tecnología de la Universidad Purdue de Indianápolis, <http://www.engr.iupui.edu/~shi/>.
- [Xiao96] Xiao J., Michalewicz Z., Zhang L. Evolutionary planner/navigator: operator performance and self-tuning. In Evolutionary Computation, 1996., Proceedings of IEEE International Conference on, pages 366 –371, may 1996. doi: 10.1109/ICEC.1996.542391.
- [Xiao97] Xiao J., Michalewicz Z., Zhang L, y K. Trojanowski. Adaptive evolutionary planner/navigator for mobile robots. Evolutionary Computation, IEEE Transactions on, 1(1):18 –28, apr 1997. ISSN 1089-778X. doi: 10.1109/4235.585889.
- [Yan07] Yan W., Clack C. D. Evolving robust GP solutions for hedge fund stock selection in emerging markets. GECCO '07: Proceedings of the 9th annual conference on Genetic and evolutionary computation. London, England. ACM Press. Pags: 2234 - 2241. 2007.
- [Yeager76] Yeager, L. International Monetary Relations, Nueva York, 1976
- [Yeo80] Yeo, B.P. Modified quasilinearization algorithm for the computation of optimal singular control. Int. J. Control, vol.32, pág 723-730, 1980.
- [Yin93] Yin, X. y Gernay, N. A Fast Genetic Algorithm with Sharing Scheme Using Cluster Analysis in Multimodal Function Optimization, en R.F. Albrecht, C.S.

- Reeves, and N.C. Steele, editors, *Artificial Neuronal Nets and Genetic Algorithms*, Proceedings of the International Conference in Insbruck, pág.450-457. Berlín, Springer-Verlag, 1993.
- [Zanakis89] Zanakakis, S.H., Evans, J.R. y Vazacopoulos, A.A. Heuristic methods and applications: a categorized survey, *EJOR*, 43, pág.88-110, 1989.
- [Zhang97] Zhang B., Ohm P., Mühlenbein H., Evolutionary induction of sparse neural trees. *Evolutionary Computacion*. 5 (2). Pags: 213-236. 1997.
- [Zhang99] Zhang B., Forecasting high frequency financial time series with evolutionary neural trees: The case of hang-sheng stock market. *Proceedings of ICAI'99*, 1999.
- [Zhao06] Zhao, J. "Quant Jocks and Tire Kickers: Does the Stock Selection Process Matter?". working paper. 2006.
- [Zhou06] Zhou A., Jin Y., Zhang Q., Sendhoff B., Tsang E (2006). "Combining model-based and genetic-based offspring generation for multi-objective optimization using a convergence criterion". 2006 IEEE Congress on Evolutionary Computation, IEEE, pp.3234-3241.
- [Zhu01] Zhu, G.Y., Henson, M.A. y Megan, L. Dynamic Modelling and Linear Model Predictive Control of Gas Pipeline Networks. *Journal of Process Control*, vol.11, pág.129-148, 2001.
- [Zydallis01] Zydallis, J.; Van Veldhuizen, D.; Lamont G. 2001. A Statistical Comparison of Multiobjective Evolutionary Algorithms Including the MOMGA-II. In *First International Conference on Evolutionary Multi-Criterion Optimization*, Eckart Zitzler, Kalyanmoy Deb, Lothar Thiele, Carlos A. Coello Coello, and David Corne, (editors), 226-240. Springer-Verlag. *Lecture Notes in Computer Science* No. 1993, 2001.
- [Zitzler99] Zitzler, Eckart. *Evolutionary Algorithms for Multiobjective Optimization: Methods and Applications*. Tesis Doctoral, Computer Engineering and Networks Laboratory. Swiss Federal Institute of Technology, Zurich, 1999.
- [Zitzler99b] Zitzler, E.; Thiele, L. 1999. Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach. *IEEE Transactions on Evolutionary Computation* 3(4):257-271.
- [Zitzler00] Zitzler, E., Deb, K., Thiele, L., Comparison of Multiobjective Evolutionary Algorithms: Empirical Results. *Evolutionary Computation*, vol.8, nº2, pág.173-195, 2000, URL [citesser.nj.nec.com/zitzler99multiobjective.html](http://citesser.nj.nec.com/zitzler99multiobjective.html).
- [Zitzler02] Zitzler, E.; Laumanns, M.; Thiele, L. 2002. SPEA2: Improving the Strength Pareto Evolutionary Algorithm, In *EUROGEN 2001, Evolutionary Methods for Design, Optimization and Control with Applications to Industrial*

Problems, K. Giannakoglou, D. Tsahalis, J. Periaux, P. Papailou and T. Fogarty (eds.), 95-100, Athens, Greece, 2002.

## **9. Summary in English**

---

**9.1 introduction**

**9.2 Main objectives of this thesis**

**9.3 Thesis structure**

**9.4 Application of evolutionary algorithms for managing trading strategy**

**9.5 Results**

**9.6 Conclusions**



## 9.1. - Introduction

The Foreign Exchange Market (also known as "Forex", abbreviation for "Foreign Exchange") is a worldwide decentralized market in which currencies are traded. This market was created with the intention of facilitating international trade, but currently the total foreign currency transactions due to international transactions of goods and services represent an almost residual percentage. Most of them are due to the purchase of financial assets. Consequently, this market is quite independent of the actual trade operations, and the differences in the price of two currencies cannot be explained exclusively by changes in trade flows. The volume of daily transactions is huge, about 5 trillion U.S. dollars (USD). There are some pairs of currencies in this market which are the most traded: eur/usd, yen/usd, usd/chf, gbp/usd, gbp/eur. They represent ninety percent of the operations performed. In recent decades some currencies have disappeared, due to the creation of others, as in the case of euro, or simply because of the replacement of national currency by a more secure and reliable international one.

On the other hand, monetary policies of the different countries make the values of these pairs vary to some extent, depending on the amount of negotiation for each pair in the market. For pairs with scarce negotiation, a sharp turn in monetary policy may result in a large variation in the exchange value. An example of the effect of these strategies can be seen in the current expansionary monetary policy of the United States, with the issue of eighty-five billion dollars every month. Other factors, such as changes in prices, unemployment, exports, etcetera, make the monetary authorities determine the policy to be followed. This makes fundamental analysis the one determining the actions to be taken by investors in the medium to long term.

In the short term, the study of the predictions are grouped into two major kinds of approaches: Quantitative, which are based on performing statistical models such as ARIMA [Uriel85], ANOVA [Peña89], autoregression models, etcetera, and Technical Analysis, which studies the time series of prices by means of a set of mathematical indicators. This work is restricted in its theoretical aspect to technical analysis and, therefore, the generation of a tool for short-term decision making in the currency market. Not only an investment tool has been developed, but also a new multi-objective technique has been implemented. It is works with an external file in which evolutionary algorithms of different nature (NSGA2, SPEA2, MoCell ...) can include non-dominated solutions at any time in order to generate buy or sell signals in the Market. This approach allows getting advantage of the capabilities of all generated solutions. If, due to the dynamism of the system, no non-dominated solutions are generated by means of a given technique, they can be generated by a different one.

The efficient-market hypothesis, developed by Fama [Fama70] in its weakest version, indicates that arbitrage is not possible in the short term, as new information is introduced in prices automatically and instantly. In this work, we can observe that the generation of the price for a currency pair is a dynamic process that requires continuous analysis of data every time they are produced. In other words, it is not instantaneous. Arbitrage is generated in the dynamics of change from the initial reaction to the stabilization in the new price. Therefore, one of the most important features of a trading system is the real-time analysis of the dynamics of the operation tick by tick, operation by operation, to observe how rates are modeled in every

frame. When we analyze a fifteen minute window eur / usd, we can see the behavior of the prices in that timescale. In those minutes the system may have added information to the prices, but in that time there have been a number of operations, between three and four hundred in a normal market, which are the ones that have modeled the price to its current value. The trading system should notice the generated new dynamics. To that end, we will make use of technical analysis and, more specifically, technical indicators, in this case MACD and stochastic, in order to obtain profit from the market.

Evolutionary computation, and in particular evolutionary algorithms, allows us to find optimized indicators for given market and temporal window. Currently there are tools making use of these concepts with different degrees of success. This work tries to go a step further, allowing the algorithm itself to determine the optimal parameters of the indicators and the timescale in which it achieves the best performance. It is a paradigm shift in technical analysis, since it is not the investor who chooses the time frame and studies investment possibilities. Now the indicator determines the best investment frameworks for the selected strategy. In other words, the indicator itself, based on the analysis of information, will tell the investor the best timescale to make an investment. This is an important quantitative and qualitative leap, as some strategies were being dismissed because of the fact that they were not applied in the proper time window.

Moreover, the objective of the investor is not only to maximize profits, but also to minimize the risks and costs of operating. Therefore, this is a multi-objective problem in which a particular strategy may have different equivalent solutions depending on some particular interests. In other words, we can find an investor who wants to minimize costs and maximize profits, and another one who wants to minimize the risks even though the costs are greater. This way, the tool determines both strategies: the global one and the trading specific one. The developed multi-objective technique includes this new contribution, by evaluating the complete set of solutions and enabling the selection of different profiles of risk, cost and benefit.

Another key element for investors is portfolio management and diversification. International companies need to have fluid capital, in foreign currency, in order to be able to buy and sale products in international markets. This means in an indirect way that they have an investment in the foreign exchange market, but they don't have any diversification. This tool would create a set of agents with different risk-benefit objectives that would allow diversification of the investment within the framework of the currency itself. This would allow them to maintain stable liquid capital with no need for insurance and fees that would reduce their benefits considerably.

There is also another major contribution in this work, which is real time calculation of capital management. Each solution generated by the evolutionary algorithm incorporates its own development of capital management, which makes the system as a whole enclose the actual operational risks.

Finally, the architecture and design of the tool enables working with any set of indicators, evolutionary algorithms and in any market, although in this work all experiments have been

performed and results have been obtained operating in the foreign exchange market with euro-dollar pair. It can also work with any online broker in real time market.

## 9.2. - Main objectives of this thesis

For all the above we have proposed in this research the following objectives::

1. ***Develop a technique multi-objetive for making investment decisions in financial markets, especially in the foreign exchange market. This will be done using evolutionary algorithms. In addition, a tool of trading will be performed to validate the theoretical basis.*** The realization of such systems involves a great deal of time and budget. In this thesis a system of trading in full real-time based on AEs will be implemented.
2. ***The multiobjective technique can incorporate any set of technical indicators, as well as all kinds of strategies. In this work, a strategy will be developed with two specific indicators. The solutions seek to maximize profit, minimize the level of risk and costs.***
3. ***The system operates in real time with the data set of the forex market. Actual data will be used for validation.***
4. ***We want to study different AEs for the realization of technique multi-objetive "trading". The idea is to analyze the features that you can implement in the developed method.***
5. ***It analyzes whether the computation time is right for the market studied. The system also will be scalable to other markets.***

1. ***The development of a technique multi-objetive to making decision in international currency markets requires the use of very solids theoretical and practical basics.***

Evolutionary computation has considerably developed in recent decades, due to the use of increasingly powerful computers which have allowed the increase of new techniques and tools. This breakthrough has occurred in both the quantitative and technical analysis. In the first, thanks to a new statistical model as ARIMA [Uriel85], ANOVA [Peña89], autoregression models, etc..., as well as new tools for working with these prediction models [Maravall96].

By the other hand, technical analysis has greatly advanced with the generation of very complex technical indicators and tools that allow their application in real time on an online broker. It has allowed that the adjustment price be increasingly instantaneous,

making traditional arbitration are disappearing and the analysis of information happens "tick" to "tick", operation by operation. This has also allowed brokers to work from anywhere in the world in real time.

The final application consists of the following modules:

- a. **Data extractor Manager:** It extracts, processes and stores the data which correspond to the time series of prices.
- b. **Solutions Manager:** It applies genetic algorithms to the strategy proposed to obtain optimal solutions. This was created so configurable mode to operate with different genetic algorithms used in this work.
- c. **Experts Manager:** The solutions obtained before are evaluated for optimal management capital. From this time, they will be called experts. This module has two objectives, managing capital and, moreover, monitors the experts detecting new signals for each new price. When a signal occurs, an order will be processed by the broker running in real time. All information that is generated in this process is stored for further processing in the management of capital.
- d. **Broker Manager:** It manages the operations in real time with the online broker account. It is independent of itself and it could run on almost all current international brokers. It's where open and closes operations and where the stop-loss dynamic is managed. It's synchronized at all times with the transmission experts.

2. ***The tool can incorporate multiple strategies based on the selection of different indicators. In this work,*** the strategy is based on two theoretical concepts such as the trend and momentum. Therefore, we have selected two indicators: El MACD, that will be the trend follower, and stochastic that will monitor the speed of price, or the momentum. Appropriate values of these will be selected based on the actual data that are occurring in the market. Moreover, there is a fundamental point and this is the selection of the time frame in which this strategy will develop its best possible efficiency. This is why a set of parameters in order to do a selection have been incorporated too. Finally, it should also include all those variables within the operational scope, such as stop-loss, take-profit or trailing-stop.

All the above elements will define the experts who will carry out the actual operation. These are generated to develop the proposed objectives; minimize risks and costs, maximize profits and diversify investment.

Furthermore, an algorithm for the management of the capital account will be developing to help the experts to enter into the market with a proper portfolio management.

3. **Tool is validated by real data. The tool, together with its theoretical foundations, will be validated** with the historical data set and its results will be analyzed in terms of a set of statistical variables. By the other hand, we will compare the results with those obtained by other methods in order to observe the improvement achieved in the optimization process proposed in this Thesis.
4. **We will make preliminary review of the application of evolutionary algorithms in the financial markets.** Thus, it may contrast the different lines of research and identify possible improvements in the developed tool. The emphasis in this part of the work will be mainly in the field of investments into the international financial system, specifically in the forex market. Technical analysis is one of the techniques most used in making investment decisions into the international currency markets.
5. **The computation time on a real-time system is essential.** Is the present work we will explore how the calculations are done in a timely manner. Furthermore, the scalability of the system to other markets is studied.

### 9.3. - Thesis structure

This thesis is organized as follow:

The first chapter discusses the history of the foreign exchange market, with particular emphasis on the nineteenth and twentieth centuries, when it gives rise to the forex market as we known today. Subsequently, we delve into fundamental concepts such as exchange rates and their variations. These markets are influenced by international monetary policy and, therefore, the basic tools are briefly discussed.

After in time, we also mentioned the Major Schools of thought and lines in this discipline. In the following sections the techniques of quantitative and technical analysis for prediction in financial markets will be discussed in this chapter is justified the choice of the technical analysis against the analysis univariate. A review of the literature in this matter, and corresponding to the application of evolutionary computing and especially the AES in the economy, is also carried out. We also studied the technical indicators which have been applied in this work. At the end of the chapter, a section of definitions of terms associated to the currency market is included.

In the second chapter, we study the techniques heuristics that guide the process of multi-objective optimization, and we present fundamental definitions which they are the theoretical basis for the optimization of problems. Moreover, the complexity of the problem is analyzed to justify the use of evolutionary algorithms for its resolution. An approach is also performed to classical methods for multi-objective optimization.

In the third chapter we reviewed the basic theoretical concepts about evolutionary algorithms, necessary to develop the application of management strategies of "trading" in the currency market. Initially this work considers briefly its history but then, fundamentals and basic terminology of genetic algorithms are also reviewed.

Chapter four explains the architecture of the developed system and its components. Selection of the various parameters and objectives for multi-objective optimization problem is indicated. We study the problems of selection and time frame of data, the key to working with evolutionary algorithms elements are discussed. A study which has selected a specific evolutionary algorithm and its parameters are also included.

The fifth chapter condenses the results of the experiments carried through to justify the usefulness of the main tool and the improvement generated over other tools. First, an analysis of the values generated by a standard solution for each of the genes comprising the chromosome is performed. This will see if the assumptions imposed in the chapter two are correct. System dynamics is also studied; this allows synthesize their performance in time. Subsequently, based on a classic chromosome, we will be adding liberty grades to see as optimization improves the non-dominated solutions found. Finally a comparison is made with other classic strategies.

The sixth chapter includes the conclusions of the work and it presents future line of research.

The seventh chapter presents the scientific publications that have led this work, and the eighth chapter covers the bibliography used in the present Thesis.

## 9.4. - Application of evolutionary algorithms for managing trading strategy

### 9.4.1 Introduction

Investors use different trading strategies for achieving their goals. In the case of technical analysis are based on technical indicators. Which are based in the time series of prices for making predictions. In this paper, evolutionary algorithms for optimizing these strategies will be used, which, as we shall see, are not only constituted by these indicators. The main goal of investor is to make a profit from an investment, but not is the only, there may be others. The most important objectives for an invensor are:

- **Profit maximization:** To achieve this objective is necessary a first right decision of investment. Also be required to have a good control of the moments of entry and exit in the market. For example, a late entry or exit too early may cause losses in a suitable operating environment initially. Another important element is the optimization of the reinvestment of benefit.
- **Minimize the risk:** investors need a stable market for to obtain benefits, and operations that minimize the deviation in its expectative and limit the maximum number of failed trades consecutively. Sometimes a winning strategy runs a number of failed transactions, which produce large losses and this not allow at the investor continue investing. At this point, it is essential the capital management, knowing how much to invest, what strategy at any given time better, without running the risk of a big loss. Here we must bear in mind that the market is constantly changing and sometimes does so in a violent manner how the announcement of an earthquake, a war etc.
- **Maximize performance:** this is linked to the number of times we entered the market, and the interest is payable on the capital borrowed and the commissions that the brokers charged on each new operation. Keep open one operation a lot of time generated many interests which can significantly impair to the profits. The fees charged by the intermediary to intervene in the market make some operations unprofitable by the low profit margin. In short, the goal is to enter as many times as possible but only to stay within the time necessary for obtained the maximum gain. If

the operation is not successful to the start is better to leave as soon as possible and seek new objectives. A good investor constantly is looking to optimize the opportunity cost. Normally the maximization of performance brings a higher profit.

As can be seen, the strategies that make up a system of trading have different objectives, and therefore, these are problems of multivariable and multi-objective optimization, and how it will look in this chapter, due to its complexity (it is NP-complete ), are not suitable to be solved by classical methods of optimization.

Throughout the previous research, knowledge and data required were obtained to establish the system architecture of "trading" with genetic algorithms in real time, the characteristics and description are show below. To check its robustness and obtain more actual results, experimental studies have been carried out on a demo account, which can be representative of any online broker that currently operates in the market.

#### 9.4.2. - Architectural Overview

The application architecture consists of four modules (Figure 114), the transmission data extraction solutions manager, the manager expert and money manager (Figure 113). Briefly each one makes the following tasks:

- **Manager data extractor (Module I):** extracts and stores the data for the time series of prices tick" by tick. These data are then processed and stored in different time spaces. This element is critical because it contains all the information for later analysis. In this case is of the order of a data input every two seconds.
- **Solution Manager (Module II):** this module used genetic algorithms together with the strategy of "trading" for obtaining optimal solutions. This manager was created of a form configurable to operate with different genetic algorithms. The solutions obtained are the basis for calculations in this module and the next. In Figure 113, one can observe the set of solutions that obtains the Pareto front generated by the module in a instant of time. Typically, the number of solutions that the system operated simultaneously on average is between eighty and one hundred and twenty, and depends on market volatility. For volatile environments is reduced and for stable is increased.






Figura 113. - Multiobjective Pareto Front

With the arrival of new data, the system goes recalculating new solutions, discarding those dominated by new ones. Generally the variation is small, indicating the robustness of the system, although as stated above is related to volatility. The recalculation time is fixed by the number of evaluations that it executes.

**Expert Manager (Module III):** This module is the engine that operating in real time and has two objectives, capital management, and monitoring of experts for decision making. The solutions obtained above are first evaluated for optimal management of capital. The number of lots to operate when it enters the market is added. This information is dynamic and constantly recalculated based on the degree of success obtained in the previous operation. After this action, the solutions are called experts, and are added to the list of operating experts. From here, each time that a new tick occurs, this check whether any kind of signal in the active experts is generated, and if is applicable, a new order is created and stored in the repository, for later to be executed by the manager of the broker. The time from the manager start command until it is executed is approximately one second. All information generated in this process is stored for to be analyzed.

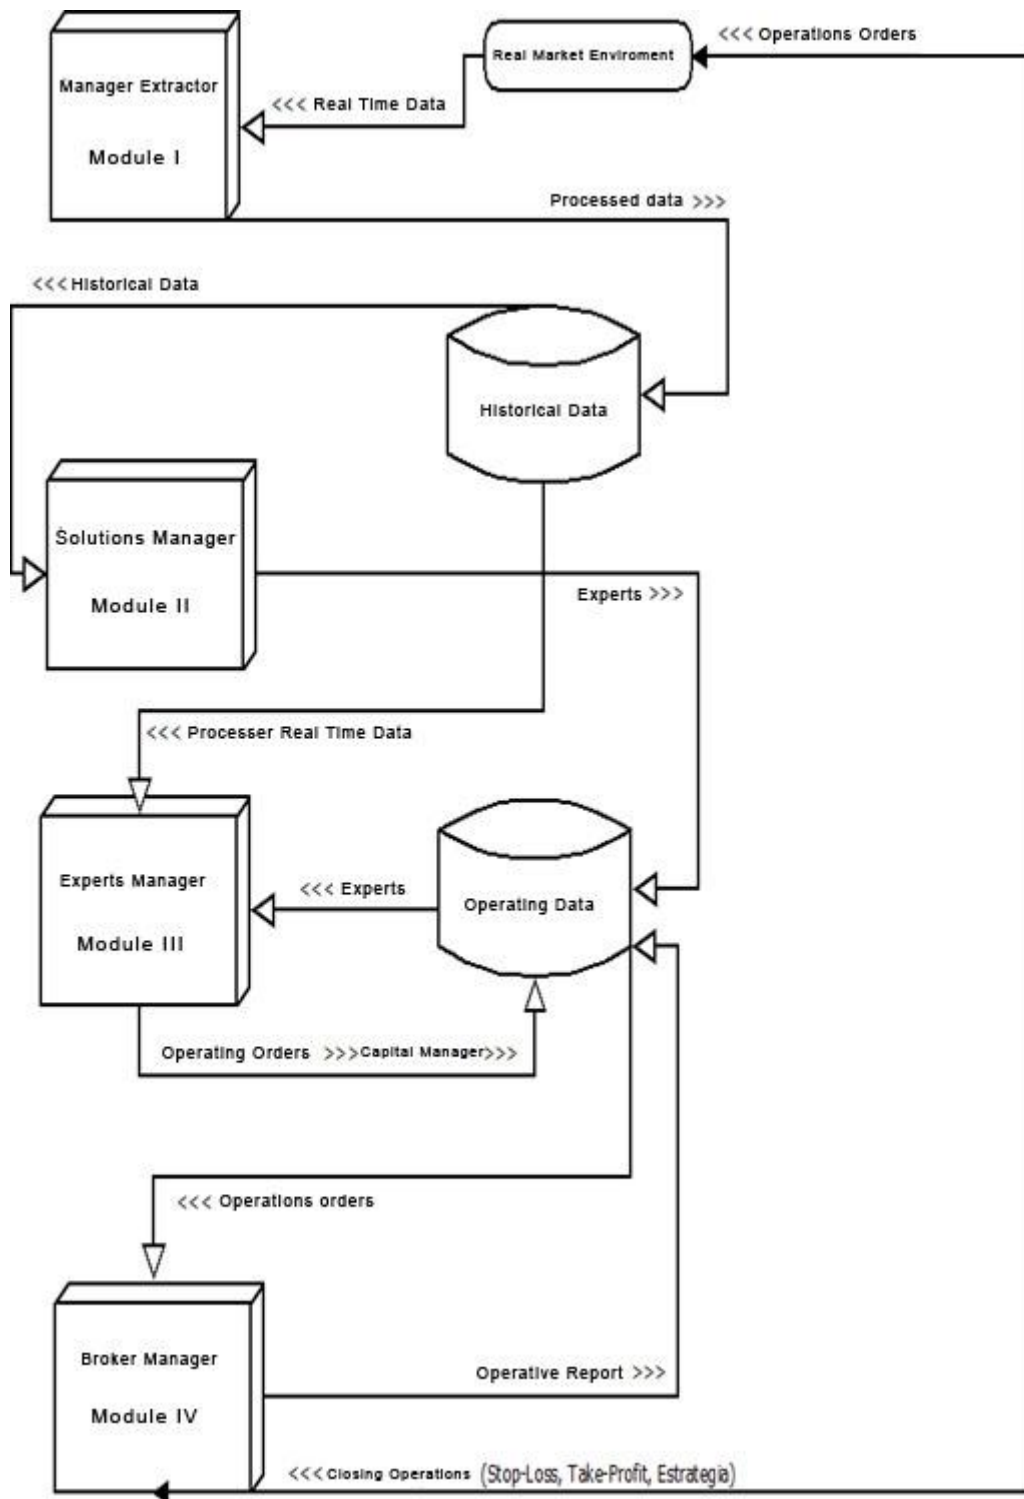


Figura 114. - System Architecture

**Broker Module (Module IV):** is the place that opens and closes the actual operations, and is synchronized with expert manager. The operations to open or closing are stored in a database and are then used for the execution of new orders. In this work it has been used mainly metatrader 4.0 [www-metatrader] along with your programming language MQL4 [www-mql4] to carry out this management. It has also been tested in the Java API that provides Dukascopy

[www-Dukascopy]. The operational decision making is independent of the used online broker. The developed application is not restricted to foreign exchange market and is therefore highly scalable.

In the following sections we will study the parameters that are part of the solutions generated by the evolutionary algorithm.

#### 9.4.3. - Definition of the proposed gene.

Definitely the gene is composed of 15 chromosomes. In Tabla 1344, we can see an example of the classical parameters, and Tabla 1445 the intervals that can they take.

MACD			Stochastic			Temporal Scale		MARKET			Param. MACD		Param. Stochastic	
MACDa	MACDb	MACDc	ESTa	ESTb	ESTc	ESCT1	ESCT2	SL	TP	TS	MACDpa	MACDpb	ESTpa	ESTpb
12	26	9	14	3	3	60	15	15	50	3	2.3	1.7	80	20

Table 44. - Each parameter specification of the complete gene.

chromosome	Origin	Intervals
MACDa	First moving average of MACD	(1,100)
MACDb	Second moving average of the MACD	(1,100)
MACDc	MACD Signal	(1,100)
ESTa	First moving average Stochastic	(1,100)
ESTb	Second moving average Stochastic	(1,25)
ESTc	Third Moving Average Stochastic	(1,25)
ESCT1	Temporal Scale for MACD	(1,1440)
ESCT2	Temporal Scale for Stochastic	(1,1440)
SL	"stop-loss"	(6,300)
TP	"take-profit"	(6,300)
TS	"trailing-stop"	(5,100)
MACDpa	Above the zero reference that allows signals can be considered.	(0.100, -0.100)
MACDpb	Below the zero reference that allows signals may be considered.	(0.100, -0.100)
ESTpa	Above the zero reference that indicates the overbought area.	(50,100)
ESTpb	Reference below zero indicates oversold.	(0,50)

Table 45. The values of the parameters of the Gene.

As we can see the sample space is huge, around  $1 \times 10^{33}$ , this allows that the use of the evolutionary algorithms is justified. All chromosomes of the gene will be represented by an integer encoding, except those belonging to MACDpb MACDpa that will have a real coding.

#### 9.4.4. - Results obtained in the algorithm selection

The algorithms multi-objective selected for the initial study was the following: NSGA-II, SPEA-II, PAES, PESA-II and MoCell. These algorithms are basic references in the literature of this knowledge area and are well suited to the type of problem to be solved. After performing the set of experiments reported in the thesis, from the global point of view, and in all data sets, the SPEA-II algorithm overcomes the rest.

The strengths of this evolutionary algorithm are:

- The benefit obtained is higher than for the rest of the algorithms discussed.
- The average deviation is less.
- The number of operations performed is greater.
- The solutions are more robust, their average length is greater.
- The number of solutions non-dominated belonging the "approximate Pareto front" is always among the best.
- In the quantification of all metrics, despite not being the best always is near of it.

#### 9.4.5. - Optimal configuration for the algorithm selected

The optimal configuration of the selected genetic algorithm is:

1. Population size:  $\mu = 100$  individuals.
3. Initialization Operator: random.
4. Selection operator: tournament selection.
5. Crossover operator: operator SBX ( $\eta = 0.9$ )
6. Mutation Operator: mutation polynomial ( $\eta = 0.08$ )
7. Operator migration: migration of the best individuals.
8. Management restrictions: none.

## 9.5. - Results

In this section techniques performed in this work are compared with other. Most of the work using only a single solution to operate, but in this case will be used all the solutions that are generated. In some cases the same solution is maintained for the entire period, from a previous optimization [Lohpetch 11]. In other cases it is changing with the arrival of new data, but in the end only one solution operates despite using different objectives for obtaining the final solutions [Bodas 13]. This selection may depend on various factors, but typically is determined by the gain. In this work 100 experiments to simulate this type of strategy is made. The best solutions for each data set will be selected and the average profit will be obtained. In Table 46 we can see the values found.

	Set 1	Set 2	Seto 3	average
Average	0.561	0.682	0.982	0.742
Deviation	0.116	0.133	0.160	0.136

Table 46. - Summary of the obtained average gain for a single solution

Another strategy selected for comparison has been "Buy & Hold". This strategy is very common to evaluate investment strategies [Chen02]. This strategy involves buying a value and keeps it for a long time. The benefit of the Buy & Hold strategy is obtained by subtracting the initial value from the final value. Possible operations are two, since the investor can bet that the value will rise or fall. In Table 47 we can observe the values obtained in both cases.

	Initial Value	Final Value	Long selling ("pips")	short selling ("pips")
Conjunto 1	1.2166	1.1852	-0.0314	0.0314
Conjunto 2	1.2118	1.2880	0.0762	-0.0762
Conjunto 3	1.5803	1.5494	-0.0309	0.0309

Table 47. - Summary of the gain for the "Buy & Hold" strategy

The last strategy that compares is the provided in this thesis. The features of these solutions are: 1 - New solutions are generated as the data are changing over time. 2 - All non-dominated solutions form the Pareto front is used. 3. - The time frames are selected by the evolutionary algorithm. The gain is calculated from the average profit achieved by the implementation of this strategy in a total of 100 experiments. In Table 48 the data summary of the results is shown.

	Set 1	Set 2	Set 3	Average
Average	18.70	36.67	46.38	33.92
Deviation	1.44	6.64	6.82	4.97

Table 48. - Summary of the gain to the Pareto front strategy

In the following figures, one for each set, the results obtained are shown. On the x-axis, strategies are displayed with the following numbers:: 1.- Strategy all the Pareto front, 2.- Only solution, 3.- Buy and Hold (Long Selling). 4. - Buy and Hold (Short Selling).




Figure 115. - The benefit to the strategies in the set 1




Figure 116. - The benefit to the strategies in the set 2




Figure 117. - The benefit to the strategies in the set 3

In conclusion, the benefits obtained by the solution provided in this work are very good, and to improve the results obtained by the other strategies. The results presented in the experimental phase allow us to conclude the following:

1. The parameter optimization of technical indicators MACD and Stochastic with SPEA-II genetic algorithm improves very significantly the results of the typical strategies and Buy & Hold and Buy & Hold.
2. Furthermore, it can be seen that the diversity of values the set of solutions obtained by the algorithm is very broad. It is also noted that slight variations lead to completely different results. The strategy of working with the entire Pareto front makes the behavior is optimal. The solutions are discarded only if they are dominated by others.
3. The values obtained by the technique used in this work are quite different from those proposed in the literature. As for the specific parameters included to control the sensitivity of the signals of operation has been verified how they try to extend the operating range to achieve the highest possible number of operations.
4. There are experts who operate despite generating losses. This is because they have a profit margin very short and they are highly dependent on dataset. One possible solution would be to put a filter that it will prevent that these will operate. The other possibility would be closing, but is ruled out, since many solutions that are good and generate profits, on some interval can produce little losses.

5. The dynamics of the system, as we have seen, is very dependent on the evolutionary algorithm itself. Although the fact every few solutions will get a new set of data makes that it be minimized.
6. Furthermore, the ability exploratory of the algorithm SPEA-II makes this tandem is very good, as discussed in chapter four. This behavior also makes grow the number of operations and therefore increases the gain.
7. On the Sets studied, the third of these is the generating more profit. In bubble charts the dependencies between parameters and their dispersion was observed.
8. In general the result obtained by the multifrequency system compared with the other strategies is significant. We also noticed that the use of no fixed windows greatly improves the results. The time measure system selected in this work, tick by tick, has generated a significant increase in your performance.

## 9.6. - Conclusions

1 - It has been developed a tool for real-time operations in the foreign exchange market. It is based on, via a multi-objective evolutionary algorithm, the optimization of a set of parameters. These are related mainly to three areas: the stock technical indicators, other specific market indicators, such as stop-loss, take-profit and trailing-stop and, finally, the corresponding time windows in which the operation takes place. The system offers high scalability to other potential financial markets. It is also completely customizable to any type of indicators or the inclusion of new parameters.

2 - The system generates a set of experts that operates autonomously in the market. They are continually evaluated to see if there are others that get better performance for the current data set, and if this occurs, then they are replaced automatically. This set consists of the entire Pareto front of solutions, they usually make up between 80 and 120 different solutions. Sometimes they can be used filters to reduce the number of experts, to limit the number of operations.

3 - Evaluation of different Evolutionary Algorithms has permitted to observe how, in general, the process of optimization works best. For the selected market in this work, the SPEA-II has reached best yield. Further adjustment of this one has resulted in a considerable increase in its ultimate performance.



4 - The tool generates for each expert some different operational conditions depending on the degree of success that has been obtained in the above range. This is very interesting, as an expert who has generated a very poor profit or even losses, it is not eliminated, but the amount of active risk can be reduced, even being able to be zero in some cases. The decision to replace an expert is solely attributable to being dominated by another. This behaviour can limit the risk as much as locally as globally for all transactions. This is one of the main objectives of any system of trading.

5 - It has been shown that the maximization of the number of transactions improves the profits. Obviously the total cost of transactions increases, but the gain far outweighs this cost. Also, when performing a large number of operations that are resolved in a very short period of time, the costs associated with interests are reduced to virtually zero. It was also noted that in general the system tended to obtain the benefits quickly.

6 – The tool has been validated by using actual data. There have been two types of experiments. In the first one the results obtained by the solution from the implemented strategies are compared with those obtained using standard values for the parameters [Elder93]. It has been seen how as the number of degrees of freedom increases in multi-objective evolutionary algorithm, the results improve significantly. In the second experiment, the aim is to compare the profit of the technique developed strategies with common stock as buy and hold, or those that use a single solution of the Pareto front [Lohpetch11]. In the latter case the results obtained by the multi- system in comparison with other strategies involve a very significant improvement.

7 - Working with tick by tick data has got a significant increase in system performance.

8 - The Experts found by the Evolutionary Algorithm show no identification feature, beyond those elements that are found in the same time interval. This indicates that there are multiple solutions that enable the generation of profits. A very important fact is also that the time windows are part of the solution, as this has been observed in the final results.

9 - The work developed here opens a line of research for the study of other indicators or selection of new parameters for them. It also allows working with other markets, especially those that allow leverage.